

UNIVERZA V LJUBLJANI  
FAKULTETA ZA RAČUNALNIŠTVO IN INFORMATIKO

# **Ocenjevanje estetike fotografij s pomočjo strojnega učenja**

Domen Pogačnik

Delo je pripravljeno v skladu s Pravilnikom o podeljevanju  
Prešernovih nagrad študentom, pod mentorstvom  
prof. dr. Franca Soline.

Ljubljana 2012



*Zahvaljujem se mentorju prof. dr. Francu Solini za nasvete in pomoč pri izdelavi pričujočega dela.*

*Robertu Ravniku se zahvaljujem za predloge, s katerimi mi je pomagal pri učinkovitejšem reševanju problema ocenjevanja estetike fotografij in zajema učnih podatkov.*

*Zahvaljujem se tudi doc. dr. Narviki Boucon za nasvete, povezane z estetiko fotografij, in Simonu Cigoju za splošne nasvete v zvezi s fotografijo.*

*Za jezikovne nasvete in pregled naloge se zahvaljujem Martini Oberman Žnidarčič.*





# Povzetek

V našem delu smo identificirali lastnosti fotografij, ki vplivajo na zaznavo estetske kvalitete fotografije. Na podlagi teh lastnosti smo definirali lahko izračunljive značilke, ki smo jih uporabili za samodejno določanje estetike fotografije ob pomoči strojnega učenja. V okviru našega dela smo definirali in implementirali 73 značilk, ki analizirajo različne vidike fotografije. Večina značilk je bila odvisna od identifikacije subjekta fotografije. Značilke smo preizkusili na dveh naborih fotografij. Za prvi eksperiment smo pridobili fotografije na spletnem portalu Flickr, pri čemer smo subjekt fotografije identificirali ročno ob pomoči izkušenih fotografov. Izkazalo se je, da je samodejno določanje estetike fotografij na tem naboru fotografij mogoče, saj smo s strojnim učenjem dosegli 95-odstotno klasifikacijsko natančnost glede na splošno oceno fotografije (9-odstotno izboljšanje glede na primerljiva dela). Ker je ročna identifikacija subjekta dolgotrajna, smo za drugi eksperiment uporabili fotografije portretov s portala DPChallenge, pri katerih smo subjekt identificirali s pomočjo detektorja obrazov. Fotografije so bile del fotografskih tekmovanj in so mejile na umetniško fotografijo. Samodejno določanje estetike fotografij v tem naboru fotografij se je izkazalo za težavnejše, a je bilo še vedno izvedljivo. Pri izvedbi strojnega učenja smo dosegli klasifikacijsko natančnost 75 odstotkov pri klasifikaciji glede na oceno fotografije uporabnikov portala (3-odstotno izboljšanje). V nadaljevanju smo poskušali odgovoriti na vprašanje, katere značilke pripomorejo k uspešni klasifikaciji fotografij, opravili smo analizo vpliva značilk in podali njihovo interpretacijo. V zaključku dajemo še nekaj smernic za nadaljnje raziskovanje.



# Abstract

The objective of this thesis is the identification of the characteristics which influence the aesthetic appeal of photographs. On the basis of these characteristics, we defined calculable features for automatic assessment of photography aesthetics using machine learning methods. For the purpose of this thesis, we defined and implemented 73 features to analyze various aspects of a photograph. The majority of the features depended on the identification of a photographic subject. The features were tested on two sets of photographs. For the first experiment, we used photographs from Flickr web portal and manually identified the subjects with the assistance of experienced photographers. The results indicated that automatic aesthetic assessment is feasible, since the use of machine learning methods provided 95 per cent classification accuracy in reference to the overall ratings of photographs (9 per cent improvement relative to comparable research). Because of lengthy manual subject identification process, the second experiment was based on photographs from DPChallenge portal and the subjects were identified with a face detection algorithm. The photographs had been submitted for contests and were nearing artistic photography. Automatic assessment proved to be challenging but still feasible. With machine learning methods, the results showed 75 per cent classification accuracy relative to the user ratings (3 per cent improvement). We specified the features which contribute to a successful classification of photographs, analyzed their influence and interpreted the results. In conclusion, we offer some suggestions for further research.



# Seznam uporabljenih kratic in simbolov

- XML – Extensible Markup Language
- MVC – Model-View-Controller
- CA – Classification accuracy
- AUC – Area under ROC curve
- ROC – Receiver operating characteristic
- RGB – red, green, blue
- HSV – hue, saturation, value
- CMYK – cyan, magenta, yellow, and key (black)
- SVM – support vector machines
- kB – kilobyte
- ORM – object-relationship mapper
- IG – information gain



# Seznam prevedenih izrazov

- Classification accuracy – klasifikacijska točnost
- Classification tree – klasifikacijsko drevo
- Cross validation – prečno preverjanje
- Information gain – informacijski prispevek
- K-fold cross validation – K-kratno prečno preverjanje
- RGB color space – barvni prostor RGB
- HSV color space – barvni prostor HSV
- CMYK color space – barvni prostor CMYK
- Feature – značilka
- Naive Bayes classifier – klasifikator Naivni Bayes
- SVM classifier – klasifikator SVM
- Majority classifier – večinski klasifikator
- Information gain ratio – razmerje informacijskega prispevka





# Kazalo

Povzetek

Abstract

<b>1</b>	<b>Uvod</b>	<b>1</b>
<b>2</b>	<b>Lastnosti dobre fotografije</b>	<b>5</b>
2.1	Enostavnost . . . . .	6
2.2	Kompozicija . . . . .	7
2.3	Barvna harmonija . . . . .	14
2.4	Vizualna kompleksnost . . . . .	14
<b>3</b>	<b>Uporabljena tehnologija in metode</b>	<b>15</b>
3.1	OpenCV . . . . .	16
3.2	SimpleCV . . . . .	19
3.3	Python . . . . .	21
3.4	NumPy . . . . .	23
3.5	SciPy . . . . .	24
3.6	Matplotlib . . . . .	24
3.7	Django . . . . .	25
3.8	Orange . . . . .	25
3.9	Metrika reliefF . . . . .	26
<b>4</b>	<b>Uporabljene značilke</b>	<b>27</b>
4.1	Barvna shema . . . . .	28

## KAZALO

4.2	Proporci fotografije . . . . .	36
4.3	Kompozicija . . . . .	36
4.4	Vizualna kompleksnost . . . . .	43
<b>5</b>	<b>Zajem učnih podatkov</b>	<b>45</b>
5.1	Nabor fotografij za prvi eksperiment . . . . .	46
5.2	Nabor fotografij za drugi eksperiment . . . . .	50
<b>6</b>	<b>Rezultati</b>	<b>57</b>
6.1	Prvi eksperiment . . . . .	59
6.2	Drugi eksperiment . . . . .	62
6.3	Diskusija rezultatov . . . . .	67
<b>7</b>	<b>Sklepne ugotovitve</b>	<b>77</b>
	<b>Dodatek A Seznam uporabljenih značilk</b>	<b>85</b>
A.1	Nabor fotografij iz portala Flickr . . . . .	85
A.2	Fotografije portretov iz portala DPChallenge . . . . .	90

# Poglavje 1

## Uvod

Z uveljavitvijo digitalne fotografije se je količina posnetih fotografij močno povečala. Zaradi nizke cene in enostavnosti digitalnega posnetka se s fotografijo ukvarja vse več ljudi, ki naredijo čedalje več posnetkov. V tej poplavi fotografij je ročna analiza fotografij pogosto zelo zamudna in težavna. Kaže se potreba po orodjih za upravljanje s fotografijami, ki so sposobna sama izbrati najboljše posnetke iz množice posnetkov v naši zbirki.

Ocenjevanje kvalitete fotografije je zelo subjektivno področje. Kriteriji za ocenjevanje se pogosto razlikujejo med različnimi ocenjevalci, tudi ko gre za profesionalne fotografe. A vendar v večini primerov obstoji konsenz, ali gre za posnetek, ko je fotograf skrbno izbral motiv in s pomočjo pridobljenega znanja, izkušenj in nenazadnje tudi primerne opreme prišel do kvalitetne fotografije, ali pa je bila slika posneta hipno, brez izbranega motiva, ko avtor posnetka nima ne dovolj znanja in tudi ne opreme za kvaliteten posnetek. Tako podobno kot v delu avtorjev Ke et al. [15] definiramo na eni strani visokokvalitetni – profesionalni posnetek in na drugi strani nizkokvalitetni – hipni posnetek.

V preteklosti so se za avtomatično ocenjevanje kvalitete posnetka uporabljale metode, ki so analizirale slike na nizkem nivoju oziroma so upoštevale zelo osnovne attribute slik [12]. Naš pristop je nasproten, analize slik smo se lotili od zgoraj navzdol. Cilj, ki smo ga želeli doseči, je razvoj skupine

visokonivojskih značilnk, ki so bliže človeškemu dojemanju kvalitete slik.

Načrtovanje visokonivojskih značilnk je zahtevno opravilo, saj tudi profesionalni fotografi za ocenjevanje fotografij uporabljajo precej neoprijemljive termine, kot so dobra kompozicija, barvna shema in osvetlitev. Zadali smo si nalogo, da te koncepte pretvorimo v konkretne značilke, ki so dovolj enostavne in hitro izračunljive. Zavedamo se, da pri ocenjevanju kvalitete slik prihaja do velike variacije pri zaznavanju kvalitete slik. Tudi zato smo naš problem omejili samo na razlikovanje med nizkokvalitetnimi in visokokvalitetnimi (profesionalnimi) posnetki. Prav gotovo pa naše delo ni namenjeno klasifikaciji umetniških del ali razlikovanju med različnimi profesionalnimi fotografijami. Klasifikacija teh del je težavna že za človeške ocenjevalce in pogosto se uporabljajo različni kriteriji pri že prej omenjeni visoki varianci pri zaznavanju kvalitete.

Kljub vsem težavam, povezanim z neoprijemljivimi kriteriji za ocenjevanje in varianco, pa obstajajo nekatere naravne zakonitosti, ki so bile potrjene že v preteklosti in so prestale preizkus časa. Fotografije izkušenih fotografov se v večini držijo pravil lepe kompozicije, najsibo to pravilo tretjin, zlato pravilo ali katero drugo uveljavljeno pravilo. Tako so te fotografije vizualno privlačnejše, kot so fotografije neizkušenih fotografov. Seveda pa obstajajo tudi fotografije izkušenih fotografov, ki ta pravila zavestno kršijo in tako ustvarjajo napetost, ki gledalce fotografij le še bolj privlači.

Sistem za ocenjevanje kvalitete fotografij je uporaben na veliko področjih. Eno izmed področij so že prej omenjena orodja za upravljanje s fotografijami. Spletni iskalniki, ki iščejo po slikah, bi sistem koristno uporabili za nadzor nad kvaliteto vrnjenih rezultatov. S tem bi vrnili najbolj relevantne in predvsem kvalitetne slike. Sistem za avtomatično ocenjevanje kvalitete fotografij bi bil lahko vgrajen tudi v fotoaparate. V preteklosti so v fotoaparate že vgradili programsko opremo za samodejno osvetlitev in ostrenje. V sodobnejših fotoaparatih pa najdemo tudi pomagala, kot je detekcija obrazov in nasmehov. Samodejno ocenjevanje estetike bi bil lahko naslednji korak pri razvoju fotoaparatov, prijaznih do uporabnika.

Področje ocenjevanja estetike fotografij je razmeroma novo in o tem še ni veliko literature. Zgodnejše raziskave so za analizo fotografij uporabljale t. i. nizkonivojske značilke, to je značilke, ki delujejo bolj ali manj neposredno na pikslih fotografije. Kasnejša dela pa so si zadala bolj ambiciozno nalogo, in sicer definirati visokonivojske značilke, ki bolj ustrezajo abstraktnim konceptom, ki jih uporabljajo fotografi. Delo avtorjev Ke et al. [15] je te visokonivojske značilke sestavilo iz nizkonivojskih značilk, kot so šum, zamegljenost, barva, osvetljenost, kontrast in prostorska porazdelitev robov. Nekatera dela so ambicioznejša in poleg teh visokonivojskih značilk raziskujejo tudi vpliv podobnosti med fotografijami [10, 11]. Pri nekaterih delih so se avtorji [5] odločili raziskati vpliv metapodatkov, ki jih naprava zapiše ob nastanku fotografije. Vendar pa se je v kasneje v delih Luo and Tang in Sun et al. izkazalo, da ti podatki ne zadostujejo za kvalitetno oceno estetike fotografije. Kasnejša dela so se zato usmerila k analizi kompozicije fotografije [17], kar so nadaljevali tudi avtorji Bhattacharya, Sukthankar in Shah [2] z opazovanjem postavitve osprednjega objekta v okvir slike ali z analizo postavitve horizonta, kadar gre za fotografije pokrajine brez izrazitega osprednjega objekta.

Problem ocenjevanja estetike fotografij smo se odločili reševati z metodami strojnega učenja. Najprej smo preučili lastnosti vizualno privlačnih fotografij, pri tem pa smo se močno naslonili na delo avtorja M. Freeman, Fotografov pogled [13], in na predhodno delo avtorjev Ke et al. [15]. V okvir preučevanja vizualne privlačnosti smo vključili tudi koncept vizualne kompleksnosti, pri katerem smo se naslonili na disertacijo avtorja G. Birкина [4]. Te lastnosti bomo opisali v poglavju 2. Tehnologijo in metode, ki smo jih uporabili pri našem delu bomo predstavili v poglavju 3. Na podlagi lastnosti dobre fotografije smo definirali 72 značilk, ki so v večini odvisne od identifikacije subjekta fotografije. Opis in implementacijo teh značilk bomo opisali v poglavju 4. V nadaljevanju bomo opisali zajem učnih podatkov za strojno učenje. Za potrebe prvega eksperimenta so lastnosti fotografij ocenili izkušeni fotografi, ki so prav tako identificirali subjekt fotografije. Za drugi

eksperiment pa smo želeli značilke preizkusiti na večji učni množici, zato smo izbrali že ocenjene fotografije portretov s portala DPChallenge [1], pri katerih smo subjekt določili ob pomoči detektorja obrazov. V 6. poglavju bomo najprej predstavili uspešnost naše metode za razlikovanje med nizko- in visokokvalitetnimi posnetki, ki smo jo dobili s strojnim učenjem. V nadaljevanju pa bomo predstavili vpliv in interpretacijo značilk, uporabljenih v naši metodi. Sklepne ugotovitve bomo zapisali v 7. poglavju.

## Poglavje 2

# Lastnosti dobre fotografije

V pričujočem poglavju bomo predstavili nekaj lastnosti dobre fotografije, na katerih temeljijo značilke, definirane v naslednjem poglavju. Za identifikacijo lastnosti dobre fotografije smo se močno naslonili na delo M. Freeman, Fotografov pogled [13], in na predhodno delo avtorjev Ke et al. [15]. Pogost problem, ki ga opazimo pri fotografijah nizke kvalitete, je premalo skrbno izbran subjekt fotografije. Tako tudi v nadaljevanju definiramo pojem hipnega posnetka, ki označuje prav problem slabo izbranega subjekta. Pri izbiri subjekta pa je prav tako treba preprečiti, da bi preostali elementi na fotografiji onemogočili razpoznavo glavnega subjekta. Način izbire subjekta smo podrobneje opisali v podpoglavju 2.1. Ko je subjekt fotografije izbran, se postavi vprašanje, kako naj bo postavljen v okvir fotografije in kakšna naj bo interakcija z drugimi objekti na sliki. Na to vprašanje nam poizkušajo odgovoriti pravila kompozicije, ki smo jih predstavili v podpoglavju 2.2. V podpoglavju 2.3 smo na kratko predstavili vpliv uporabljene barvne sheme na dožemanje estetske kvalitete fotografije. Nazadnje pa smo opisali vizualno kompleksnost in njen vpliv na zaznavanje estetske kvalitete fotografije.



Slika 2.1: Primer fotografije z zamegljenim ozadjem, ki omogoča, da se gledalec lahko osredotoči na subjekt fotografije.

## 2.1 Enostavnost

Kvalitetni posnetki težijo k čim večji enostavnosti, zato je pri teh fotografijah mogoče nemudoma identificirati subjekt slike (interesni center fotografije). Gledalec si naredi prvi vtis o sliki na podlagi subjekta, šele potem raziskuje druga področja slike in se nenazadnje tudi vrne k subjektu. V nasprotju s kvalitetnimi posnetki pa hipni posnetki nemalokrat vnašajo v sliko nepomembne in predvsem moteče elemente, ki gledalca zmedejo in tako otežujejo razpoznavo subjekta. Zato so te fotografije tudi vizualno manj privlačne.

Dobre fotografije lahko dosežejo enostavnost na več načinov. Najlažji način je, da si izberemo, ko je to mogoče, enostavno ozadje, kot so na primer nebo, pesek itd., saj je to komplementarno subjektu. Tako ob pomoči barvnega kontrasta dosežemo, da subjekt na sliki izstopa. Podoben efekt dosežemo tudi z razliko med osvetlitvijo subjekta v primerjavi z ozadjem. Najbolj uporabna tehnika pa je preprosto postaviti ozadje izven fokusa, ki ima za rezultat zamegljeno ozadje, saj to gledalcu omogoči, da se lažje osredotoči na subjekt fotografije. Primer zamegljenega ozadja lahko vidimo na sliki 2.1.




## 2.2 Kompozicija

Pri določanju kompozicije se vse vrti okoli subjekta fotografije. Najprej se moramo vprašati, ali je interakcija s preostalimi predmeti v okolici pomembna za vsebino fotografije. Ta odločitev vpliva na kasnejšo izbiro drugih elementov poleg subjekta. Pri fotografiji smo glede postavljanja elementov nekoliko bolj omejeni kot pri drugih umetniških delih. A vendar lahko vplivamo na postavitev elementov že pri fotografiranju, in sicer z manipulacijo vidnega polja in spreminjanjem perspektive fotografije. Tako postavljeni elementi, ki upoštevajo osnovne lastnosti organizacije, tvorijo harmonično celoto ali enotnost.

Pri določanju postavitve elementov je pomembno, po kakšni poti želimo, da potuje gledalčev pogled. Pri tem si lahko pomagamo z uporabo različnih črt in oblik. Prav tako je pomembna tudi njihova orientacija, saj gledalcu pomagajo pri pravilnem dožemanju fotografije (kot si je zamislil fotograf). Elementi na sliki so ponavadi različnih oblik in velikosti, zato se pojavi vprašanje ravnotežja med njimi. Manjši objekti z močnim kontrastom imajo večji vpliv kot večji monotoni elementi. Ti elementi predstavljajo sile in človeško oko si jih želi uravnovesiti tako, da doseže harmonijo tj. stanje, ki je vizualno prijetno. Elementi se lahko tudi ponavljajo in s tem ustvarjajo vzorce ali pa fotografiji dajejo občutek ritma. Prazen prostor med elementi imenujemo negativni prostor. Ta očem omogoči, da se spočijejo, in se prav tako šteje za pomembno lastnost kompozicije.

Med bolj objektivno definiranimi lastnostmi pa je prav gotovo geometrija kompozicije fotografije, ki si jo bomo bolj podrobno ogledali v nadaljevanju. Čeprav opisane lastnosti omogočajo kvalitetno kompozicijo, lahko zavestno kršenje teh lastnosti prav tako pripelje do izjemnih del.

Pri določanju geometrije kompozicije umetniškega dela obstaja več pristopov oziroma izkustvenih pravil. Najbolj znano pravilo je prav gotovo zlati rez, ki ga bomo opisali v nadaljevanju.



Slika 2.2: Pravokotnika v zlatem razmerju.

### 2.2.1 Zlati rez

Zlati rez je kompozicijsko pravilo, ki temelji na zlatem razmerju. Dve količini sta v zlatem razmerju ( $\varphi$ ), kadar je razmerje vsote obeh količin in večje izmed količin enako razmerju večje in manjše količine (enačba 2.1). Vrednost zlatega razmerja je približno 1,62. Grafično ponazoritev tega pravila lahko vidimo na sliki 2.2.

$$\frac{a+b}{a} = \frac{a}{b} = \varphi \quad (2.1)$$

Z upoštevanjem zlatega razmerja tako definiramo dve horizontalni in dve vertikalni črti, kot to lahko vidimo na sliki 2.3. Pomembni elementi naj bi se nahajali vzdolž ene izmed teh črt ali na presečišču teh dveh črt.



Slika 2.3: Primer fotografije z vrisanimi štirimi črtami, ki delijo sliko v zlatem razmerju.)

### 2.2.2 Zlata spirala

To manj znano pravilo prav tako temelji na zlatem razmerju. Njegov namen je zavedanje, da fotografija potrebuje nekaj, kar vodi oko opazovalca do središča kompozicije, najsibo to črta ali pa več objektov. Primer fotografije s skonstruirano spiralo je prikazan na sliki 2.4.

Poenostavitev zlatega reza je pravilo tretjin, ki je opisano v nadaljevanju.

### 2.2.3 Pravilo tretjin

Pravilo tretjin je izkustveno pravilo ali smernica, ki se pogosto uporablja v slikarstvu, pri fotografiji in oblikovanju. Ukvarja se z umestitvijo elementov, pomembnih za fotografijo. Najpomembnejši element fotografije ali subjekt naj ne bi bil v središču fotografije, razen če je zaželen simetričnost fotografije. Pravilo razdeli sliko na 9 enakih delov z dvema enakomerno oddaljenema horizontalnima črtama in z dvema prav tako enakomerno oddaljenema vertikalnima črtama. Pravilo pravi, da bi morali pomembni elementi ležati ob teh črtah ali na njihovih presečiščih. Primer fotografije z dvema različnima obrezoma, pri katerem drugi obrez upošteva pravilo tretjin, lahko



Slika 2.4: Primer fotografije z vrisano zlato spiralo. Opazimo lahko, da se subjekt fotografije nahaja blizu središča spirale.

vidimo na sliki 2.5.


#### 2.2.4 Rabatment

Rabatment pravokotnika je kompozicijska tehnika, ki se uporablja za lažje postavljanje objektov na sliko ali za njeno delitev. Vsak pravokotnik vsebuje dva implicirana kvadrata, katerih velikost stranice je določena z velikostjo krajše stranice danega pravokotnika. Torej, tako definiran kvadrat zajema krajšo pravokotnikovo stranico, dve enako veliki stranici, paralelni z daljšo stranico pravokotnika, ter četrto imaginarno stranico, ki ji rečemo tudi rabatment. Ponazoritev pravila je prikazana na sliki 2.6.

Teorija, ki podpira to kompozicijsko tehniko, pravi, da so kvadrati tako enostavna in osnovna geometrijska oblika, da jih človeški možgani iščejo tudi nezavedno in opravljajo delitev okvirja umetniškega dela po pravilu rabatment. Primer fotografije, ki upošteva pravilo rabatment, je prikazan na sliki 2.7.



Slika 2.5: Fotografiji z istim motivom vendar z drugačnim obrezom. Leva fotografija ne upošteva pravila tretjin. Desna slika, ki to pravilo upošteva, je privlačnejša.



Slika 2.6: Ponazoritev pravila rabatment, pri katerem je s prekinjeno črto označena četrta imaginarna stranica impliciranega kvadrata.



Slika 2.7: Primer umetniškega dela, v katerem je bilo uporabljeno pravilo rabatment. Moški, ki bi ga identificirali kot subjekt fotografije, se nahaja vzdolž četrte imaginarne stranice.

### 2.2.5 Liho pravilo

Človeški možgani so nagnjeni k združevanju elementov v pare. Tako v primeru, da je na fotografiji sodo število elementov, možgani nimajo težjega dela z iskanjem parov in simetrije. Zato se takšne fotografije pogosto zdijo puste. Liho pravilo nam zato pravi, da v fotografijo, če je le mogoče, vstavimo liho število elementov. Če imamo predmet, ki predstavlja subjekt fotografije, mu dodamo še dva podporna objekta namesto enega samega. Pogost primer uporabe tega pravila je kompozicija treh elementov, ki med seboj tvorijo obliko trikotnika ali črte. Pravilo izgubi pomen, ko je število elementov preveliko.

### 2.2.6 Pravilo prostora

Pravilo pravi, da v primeru, ko želimo poustvariti iluzijo gibanja ali ponazoriti vsebinsko praznino, pustimo prazen prostor v smeri, kamor gleda oseba

ali predmet na sliki. Če fotografiramo tekača, nam prazen prostor pred njim daje občutek gibanja v to smer.

### 2.2.7 Simetrija

Kadar govorimo o organizmih, dojemamo simetrijo kot prikaz zdravja posameznega organizma. Zelo očiten primer simetrije opazimo pri človeškem obrazu, bilateralno simetrijo, ki razdeli sliko v dve zrcalno enaki polovici. Simetričnost je v tem primeru vizualno privlačnejša. Posledično ima simetrija podoben vpliv na dojetje drugih objektov. Manj opazen vpliv ima simetrija na dojetje enostavnosti umetniškega dela, ki v gledalcu vzbuja občutke varnosti, urejenosti in domačnosti. Kljub človeški psihološki naravnosti k simetriji pa težnja k čezmerni simetriji učinkuje dolgočasno in nezanimivo. Ljudje si želimo raziskovanja novih možnosti, ki jih v čezmerno simetričnih delih primanjkuje. Pravi izziv za umetnika je poiskati pravo razmerje med simetrijo in asimetrijo.

### 2.2.8 Perspektiva

Perspektiva gledalca lahko pomembno vpliva na njegovo dojetje slike. Če fotografiramo objekt odzgoraj, navidezno zmanjšamo njegovo velikost, nasprotno pa fotografiranje odspodaj navidezno poveča predmet in mu daje veličino. Če je fotografija nastala z višine objekta, doživljamo tak objekt kot nam enakovreden.

### 2.2.9 Horizont

Pri fotografijah krajine in morja, ki nimajo izrazitega subjekta, pridobi veljavo pozicija ločnice med zemljo (ali morjem) in nebom. Ločnica ali horizont naj ne bi delila fotografije na dva enako velika dela, ampak naj bi s svojimi proporci dala poudarek bodisi nebu ali zemlji.

## 2.3 Barvna harmonija

Nekatere barvne kombinacije pri ljudeh vzbudijo prijeten občutek, zato pravimo, da so v harmoniji [7]. Poznamo več tipov teh kombinacij, od katerih so najbolj znane analogna, komplementarna in triadna barvna shema.

Analogne barvne sheme sestavljajo barvni odtenki, ki so si med seboj sosednji na barvnem krogu. Ti barvni odtenki se med seboj dobro ujemajo in ustvarjajo občutek udobja in spokojnosti.

Barvni odtenki sestavljajo komplementarno barvno shemo, kadar so na nasprotni strani barvnega kroga (npr. rdeča in zelena). Velik kontrast komplementarnih barvnih odtenkov ustvarja živ videz fotografije, še posebno takrat, kadar so uporabljeni barvni odtenki polno nasičeni. Komplementarne barvne odtenke je treba uporabljati previdno, saj je ob njihovi čezmerni uporabi fotografija kričeča.

Triadno barvno shemo sestavljajo barvni odtenki, ki so enakomerno porazdeljeni v barvnem krogu. Ti barvni odtenki ustvarjajo živ videz tudi, če niso popolnoma nasičeni.

## 2.4 Vizualna kompleksnost

V umetniškem delu, kot so tudi fotografije, človeško oko zaznava različne oblike. Te oblike imajo svojo barvo, teksturo in položaj glede na druge elemente in glede na okvir slike. Več oblik, kot jih človeško oko zazna, bolj zaznavamo delo kot kompleksno. Vizualno kompleksnost bi lahko drugače definirali tudi kot najkrajši način za opis umetniškega dela [4]. Vizualna kompleksnost igra pomembno vlogo pri zaznavanju estetske kvalitete umetniškega dela. Za bolj kompleksna dela je potrebno več znanja in vloženega truda, zato so take fotografije vizualno privlačnejše [4].



## Poglavje 3

# Uporabljena tehnologija in metode

Pri izbiri tehnologije smo največ pozornosti namenili knjižnici za računalniški vid. Po pregledu področja smo se odločili za knjižnico OpenCV na podlagi velikosti uporabniške skupnosti, uglednih imen uporabnikov knjižnice in količine literature, ki je na voljo za knjižnico [6]. Knjižnica OpenCV omogoča programiranje v programskem jeziku C/C++, vendar ponuja tudi vmesnik za programski jezik Python. Programski jezik Python smo izbrali, ker sta nam bili v fazi raziskovanja in prototipiranja sistema pomembni predvsem hitrost in enostavnost razvoja, ne pa toliko hitrost rešitve. Kasneje smo ugotovili, da vmesnik knjižnice OpenCV za jezik Python ne izkorišča dinamičnosti jezika Python (pri kreiranju podatkovnih struktur), zato smo se odločili za uporabo visokonivojske knjižnice SimpleCV, ki uporabniku ponuja prijazen dostop do metod knjižnice OpenCV. Odločitev za jezik Python se je prav tako skladala z izbiro orodja za strojno učenje Orange. Tudi ta ponuja vmesnik za programiranje v tem jeziku. V okviru naloge za Prešernovo nagrado smo izdelali tudi spletno aplikacijo za označevanje in ocenjevanje fotografij, za kar smo vnovič uporabili programski jezik Python in pa ogrodje, imenovano Django.

### 3.1 OpenCV

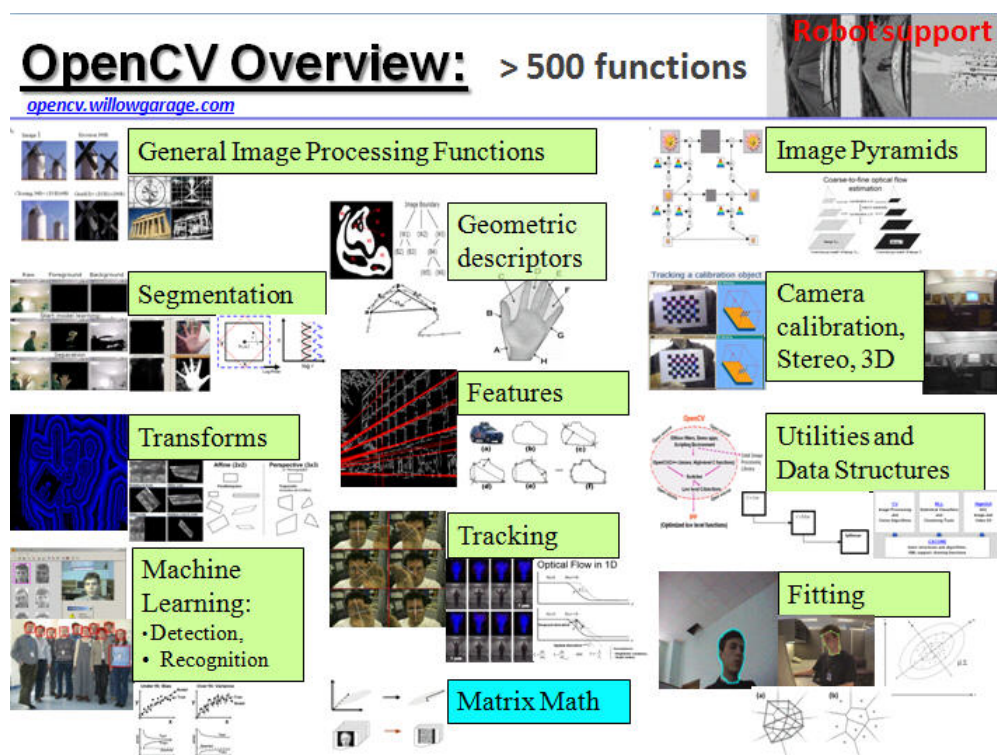
Za opravila, povezana z računalniškim vidom, smo uporabili knjižnico OpenCV (Open Source Computer Vision). Na našo odločitev za OpenCV so vplivali velikost uporabniške skupnosti, ugledna imena uporabnikov knjižnice in količina literature, ki je na voljo za knjižnico [6]. OpenCV je odprtokodna knjižnica z algoritmi, ki se uporabljajo v računalniškem vidu. Knjižnica je izdana pod licenco BSD in je tako na voljo tudi za komercialno uporabo. Razvita je bila v laboratorijih podjetja Intel, trenutno pa nad njo bedi podjetje Willow Garage. Knjižnica podpira vse najbolj uporabljane operacijske sisteme: Windows, Linux, Mac OS, prav tako pa tudi mobilne operacijske sisteme: Android, Maemo, iOS. Glavni fokus knjižnice je procesiranje slik v realnem času. Kot zanimivost, knjižnica je bila uporabljena v zmagovalnem avtomobilu ekipe iz Stanforda na tekmovanju Darpa Grand Challenge [19].

Knjižnica vsebuje več kot 500 funkcij. Te funkcije pokrivajo področja računalniškega vida, kot so: prepoznavna in sledenje gibanja, prepoznavna obrazov, prepoznavna kretenj, interakcija človek - računalnik, mobilna robotika, identifikacija objektov, segmentacija, stereovid. Shemo funkcionalnosti prikazuje slika 3.1.

Čeprav je knjižnica implemetirana v jeziku C in C++, so zanjo na voljo vmesniki do jezikov, kot so Python, Ruby, Matlab, C#, Java.

Nabor funkcionalnosti:

- upravljanje s slikovnimi podatkovnimi strukturami (alokacija podatkov, dealokacija, kopiranje, konverzija),
- branje in zapisovanje slik/video preko naprav V/I,
- upravljanje z matrikami in vektorji (linearna algebra),
- dinamične strukture (sezname, vrste, množice, drevesa, grafi),
- osnovni algoritmi za procesiranje slik (filtri, detektorji robov, vzorčenje, interpolacija, pretvorba barv, morfološke operacije, histogrami, piramide slik),



Slika 3.1: Prikaz nabora funkcionalnosti knjižnice OpenCV.

- strukturna analiza (povezane komponente, Houghova transformacija),
- kalibracija kamere (stereo korespondenca),
- analiza gibanja (segmentacija, sledenje),
- prepoznavanje objektov,
- osnovni GUI (prikaz slik in videa, upravljanje z miško in tipkovnico, drsniki),
- označevanje slik (črt, poligonov, izris teksta).

Primer enostavnega programa z uporabo knjižnice OpenCV:


spodnji program najprej s piramidnim vzorčenjem pomanjša sliko, jo pretvori v sivinsko obliko, nato pa na zmanjšani sivinski sliki izvede detektor robov Canny. Obe sliki prikažemo na zaslonu. Rezultat operacij prikazujeta sliki 3.2 in 3.3.

```
int _tmain(int argc, _TCHAR* argv[])
{
    IplImage* img = cvLoadImage( "MGC.jpg" );
    cvNamedWindow( "Example3-in" );
    cvNamedWindow( "Example3-out" );

    // Show the original image
    cvShowImage("Example3-in", img);

    // Create an image for the output
    IplImage* out = cvCreateImage( cvGetSize(img),
                                   IPL_DEPTH_8U, 3 );

    // Perform a Gaussian blur
    cvSmooth( img, out, CV_GAUSSIAN, 11, 11 );
```



Slika 3.2: Originalna slika (levo) in slika, pri kateri smo izvedli Gaussovo glajenje (desno). Slika je del vodiča, na spletnih straneh Drexel University [16].


```
// Show the processed image
cvShowImage("Example3-out", out);

cvWaitKey(0);
cvReleaseImage( &img );
cvReleaseImage( &out );
cvDestroyWindow( "Example3-in" );
cvDestroyWindow( "Example3-out" );
return 0;
}
```

Vir: <http://dasl.mem.drexel.edu/~noahKuntz/openCVTut1.html>

## 3.2 SimpleCV

Ugotovili smo, da vmesnik knjižnice OpenCV za jezik Python ne izkorišča dinamičnosti jezika Python, npr. pri kreiranju podatkovnih struktur, zato smo



Slika 3.3: Rezultat detektorja robov Canny. Slika je del vodiča, na spletnih straneh Drexel University [16].

se odločili za uporabo visokonivojske knjižnice za jezik Python, imenovane SimpleCV. Knjižnica v osnovi ponuja uporabniku prijazen dostop do metod, ki jih ponuja knjižnica OpenCV, to pa še nadgradi z implementacijo nekaterih pogostejših opravil na področju računalniškega vida. Glavno vodilo razvijalcev te knjižnice oziroma ogrodja je prav enostavnost uporabe. Prav zaradi želje po enostavnem in učinkovitem ogrodju so razvijalci poleg knjižnice OpenCV integrirali tudi uporabne knjižnice Python, kot so PIL, Numpy in Scipy.

Funkcionalnost ogrodja SimpleCV:

- detekcija značilnk,
- detekcija robov, blobov,
- filtriranje in sortiranje značilnk po lokaciji, barvi, kvaliteti in velikosti, manipulacija slik in pretvorba med formati,
- zajem videa s spletnih kamer, Kinecta, vmesnika Firewire, kamer IP in mobilnih telefonov.



Slika 3.4: Rezultat algoritma, ki izvede prepoznavo obrazov.

Primer enostavnega programa:

program zajame sliko s spletne kamere in ob pomoči Haarovih značilk, podanih v deskriptorju XML, poišče obraze na podani sliki. Rezultat operacije prikazuje slika 3.4.

```
from SimpleCV import *  
  
img = Image('lenna1.png')  
faces = img.findHaarFeatures('haarcascade_frontalface_alt.xml')  
if faces:  
    for face in faces:  
        face.draw()  
img.show()
```

### 3.3 Python

Za potrebe izračuna značilk fotografij, obdelave podatkov in izdelave spletne aplikacije smo potrebovali programski jezik, ki je enostaven in omogoča hiter

razvoj. Pomembno vlogo pri izbiri sta imeli tudi knjižnica za računalniški vid SimpleCV in pa orodje za strojno učenje Orange, saj oba ponujata vmesnik za programski jezik Python.

Python je splošnonamenski visoko nivojski jezik s filozofijo, ki teži k enostavnosti uporabe, uveljavljanju dobrih praks kodiranja in dobre berljivosti kode. Prav tako teži k enostavni sintaksi in se drži principa DRY, ki je pogoj za učinkovit jezik.

Python podpira več programskih paradigem, kot so objektno orientirana, imperativna in v manjšem obsegu funkcionalna paradigma. Je dinamično tipiziran jezik s samodejnim upravljanjem s pomnilnikom. Python je najpogostejše uporabljen kot skriptni jezik, podobno kot jeziki PHP, Ruby in Perl, vendar Python omogoča še veliko več. Z uporabo knjižnic lahko program, napisanem v programskem jeziku Python, prevedemo in zapakiramo v izvršljivo datoteko. Prav tako za Python obstajajo knjižnice, ki nam omogočajo gradnjo grafičnih uporabniških vmesnikov za namizne aplikacije.

Interpreterji Python so na voljo za vse najpogejšje uporabljene operacijske sisteme. Referenčna implementacija interpreterja Python je izdana pod odprtokodno licenco. Vzdržuje ga neprofitna organizacija Python Software Foundation. Obstajajo pa tudi alternativne implementacije, kot sta IronPython in Jython, ki teče v javanskem navideznem stroju.

Python se večinoma uporablja kot skriptni jezik za spletne aplikacije. Prek vmesnika WSGI je možna povezava s spletnim strežnikom Apache. Spletna aplikacijska ogrodja, kot so Django, Pylons, TurboGears itd., nam omogočajo hiter razvoj kompleksnih spletnih aplikacij.

Interpreter Python je standardna komponenta popularnih Linux distribucij kot so Ubuntu, Red Hat, Fedora, Gentoo, itd. V teh primerih se uporablja kot jezik, v katerem so napisani inštalacijski programi, orodja za upravljanje s paketi in druga administracijska orodja. Prav tako je bil Python interpreter večkrat uspešno integriran v različne programske pakete kot skriptni jezik. Sem spadajo Blender, Maya, GIMP itd. Python je tudi eden prvih jezikov, uporabljenih v okolju Google App Engine.



Zaradi modularne arhitekture, enostavne sintakse in orodij za procesiranje teksta je Python zelo dobro sprejet v akademskem svetu. Pogosto se uporablja za procesiranje naravnega jezika in strojno učenje.

Primer enostavnega programa v programskem jeziku Python:

program si zabeleži trenutni lokalni čas, nato pa izpiše, katero aktivnost trenutno opravljamo.

```
from time import localtime

activities = {8: 'Sleeping',
              9: 'Commuting',
              17: 'Working',
              18: 'Commuting',
              20: 'Eating',
              22: 'Resting' }

time_now = localtime()
hour = time_now.tm_hour

for activity_time in sorted(activities.keys()):
    if hour < activity_time:
        print activities[activity_time]
        break
else:
    print 'Unknown, AFK or sleeping!'
```

## 3.4 NumPy

NumPy je ena izmed ključnih knjižnic za znanstveno obdelovanje podatkov v programskem jeziku Python. Glavna funkcionalnost paketa so predvsem uporabne funkcije s področja linearne algebre, poskrbi pa tudi za upravljanje

podatkovnih struktur, povezanih s temi algoritmi. Knjižnica se uporablja tudi v paketu SimpleCV. Na voljo je pod odprtokodno licenco BSD.

## 3.5 SciPy

SciPy je še ena v zbirki ključnih knjižnic Python, ki se uporabljajo v matematiki, znanosti in tehniških vedah. Uporabljena je tudi v paketu SimpleCV. Knjižnica gradi svojo funkcionalnost v okolju Python na že prej omenjeni knjižnici NumPy.

Nabor funkcionalnosti pokriva področja:


- statistike,
- optimizacije,
- numerične integracije,
- linearne algebre,
- Fourierjeve transformacije,
- procesiranja signalov,
- procesiranja slik.

Knjižnica je na voljo pod odprtokodno licenco BSD.

## 3.6 Matplotlib

Pri izračunu značilik fotografij smo si večkrat pomagali z vizualizacijo različnih količin, za kar smo uporabili knjižnico Matplotlib. Knjižnica se zgleduje po ukazu `plot` v programskem paketu Matlab in omogoča izris različnih tipov grafov in diagramov. Primer vizualizacije, narejene s to knjižnico, je prikazan na sliki 3.5. Knjižnica deluje na vseh glavnih platformah.

Primer uporabe:



Slika 3.5: Primer vizualizacije podatkov s pomočjo knjižnice Matplotlib.

```
x = randn(10000)
hist(x, 100)
```

## 3.7 Django

Za pridobivanje učnih podatkov smo izdelali spletno aplikacijo za označevanje in ocenjevanje fotografij. Za ta namen smo izbrali spletno programsko ogrodje za programski jezik Python, imenovano Django, ki je namenjeno hitremu razvoju spletnih aplikacij. Podpira razvoj aplikacij po vzorcu MVC. V osnovi zagotavlja pretvornik ORM, ki nam omogoča abstrakcijo podatkovne baze na način, da s podatki upravljamo z uporabo podatkovnih modelov v programskem jeziku Python. Omogoča delo z obrazci, ponuja sistem za avtentikacijo in druge pogosto uporabljane komponente.

## 3.8 Orange

Za izvedbo strojnega učenja in analizo značilk smo izbrali programski paket Orange [9]. Programski paket Orange je odprtokodno orodje, ki implementira algoritme za strojno učenje ter tudi analizo in vizualizacijo podatkov. Razvito je bilo v laboratoriju za umetno inteligenco (sedaj bioinformatiko) Fakultete za računalništvo in informatiko Univerze v Ljubljani.

Možna načina uporabe paketa sta naslednja:

1. prek grafičnega vmesnika: uporabljamo gradnike, ki nam jih ponuja

orodje Orange Canvas,

2. uporabljamo knjižnico Orange za Python.

### 3.9 Metrika reliefF

Določanje kvalitete značilk je pomemben del procesa strojnega učenja, saj uporaba neustreznih in šumnih značilk negativno vpliva na klasifikacijsko natančnost katerekoli metode. Tudi v našem primeru smo se srečali z velikim številom definiranih značilk, za katere nismo bili vedno prepričani, če se bodo izkazale za uporabne pri razlikovanju med nizko- in visokokvalitetnimi fotografijami. Zato se kaže potreba, da te značilke ocenimo in na podlagi te ocene izberemo najboljše značilke. V našem delu smo za to oceno uporabili metriko reliefF, ki jo bomo opisali v nadaljevanju.

Algoritem za računanje metrike reliefF sta razvila Kira in Rendell, kasneje pa ga je izboljšal I. Kononenko [18]. Algoritem za vsak učni primer izračuna najbližji primer iz istega razreda (najbližji zadetek) in najbližji primer iz nasprotnega razreda (najbližji pogrešek) in na takšen način meri uporabnost značilke glede na njeno sposobnost razlikovanja med podobnimi primeri. V nasprotju z večino heurističnih metod za ocenjevanje kvalitete značilk ne predpostavlja neodvisnosti atributov in je zato bolj uporaben pri realnih problemih, pri katerih je veliko interakcije med atributi.

## Poglavje 4

# Uporabljene značilke

Na podlagi lastnosti dobrih fotografij smo definirali množico značilk, ki opisujejo različne vidike fotografije. Te značilke smo kasneje uporabili v obeh naših eksperimentih, v katerih smo ob pomoči strojnega učenja razlikovali med visoko- in nizkokvalitetnimi fotografijami. Kot že v delih pred nami [2, 17] smo dali velik poudarek osprednjemu objektu ali subjektu fotografije v relaciji s celotno fotografijo in z njenim ozadjem. Subjekt fotografije smo v prvem delu naše analize določili ročno ob pomoči izkušenih fotografov, v drugem delu pa ob pomoči detektorja obrazov. V obeh primerih je bil subjekt označen kot pravokotna regija na sliki. Z definicijo pozicije in velikosti subjekta smo lahko definirali značilke, ki opisujejo različne kvalitete subjekta in tudi primerjavo kvalitet subjekta s celotno fotografijo. Od 73 definiranih in implementiranih značilk je kar 58 značilk odvisnih od definicije subjekta.

Implementirane značilke lahko na splošno razdelimo v 4 kategorije, in sicer na značilke, ki opisujejo: 1. barvno paleto fotografije, 2. proporce fotografije, 3. kompozicijo fotografije in 4. vizualno kompleksnost.

V okviru analize barvne palete smo si ogledali:

- število barvnih odtenkov,
- povprečen odtenek,
- število dominantnih barv,

- povprečno dominantno barvo,
- barvno harmonijo,
- povprečno nasičenost barve,
- povprečno osvetlitev,
- povprečno intenzivnost pikslov,
- kontrast med subjektom in celotno sliko.

Vse zgoraj našteje lastnosti fotografij, razen seveda zadnje postavke, smo izračunali na subjektu fotografije, na ozadju in na celotni sliki. Prav tako smo izračunali razliko izračunanih vrednosti med subjektom in ozadjem ter subjektom in celotno fotografijo.

Naslednja kategorija lastnosti, ki smo jo opazovali, so bili proporci fotografije. V okviru analize proporcij smo preučili razmerje velikosti stranic fotografije in tudi velikost subjekta v primerjavi s celotno sliko.

V okviru analize kompozicije smo si ogledali, koliko postavitev subjekta fotografije sledi različnim pravilom kompozicije. Pravila, ki smo si jih ogledali, so bila: 1. pravilo tretjin, 2. zlato pravilo in 3. rabatment. Poleg analize kompozicijskih pravil smo si ogledali, za koliko je subjekt oddaljen od stranic fotografije. Nazadnje smo naredili še analizo prostorske porazdelitve robov, s čimer smo ugotavljali, kje na fotografiji je največ dogajanja.

Nazadnje smo si ogledali vizualno kompleksnost fotografije, ki jo predstavimo z dvema značilkama: 1. velikostjo datoteke v kB in 2. številom detektiranih robov na fotografiji.

## 4.1 Barvna shema

### 4.1.1 Predstavitev barv

Ko analiziramo barve, uporabljene na fotografiji, je treba najprej razumeti, kako so barve sploh predstavljene. Zato naj predstavimo koncept barvnega

prostora, ki opisuje, kako so te barve zapisane. Najpogostejša je uporaba barvnega prostora RGB, ki je sestavljen iz treh barvnih komponent: rdeče, zelene, modre. Med drugimi pogosto uporabljenimi prostori sta še CMYK in HSV. V nadaljevanju bomo opisali barvna prostora RGB in HSV, ki smo ju uporabili v naši nalogi za Prešernovo nagrado.

### 4.1.2 Barvni prostor RGB

To je aditivni barvni prostor, v katerem z mešanjem treh komponent poustvarimo široko paletu barv. Pogosto se uporablja pri vzorčenju, zapisu in prikazu slik na različnih elektronskih napravah, kot na primer na računalniških zaslonih (CRT, LCD), TV-zaslonih (LCD, plazma) in pa tudi v fotoaparatih in video kamerah.

Za nastanek barve v prostoru RGB potrebujemo 3 barvne odtenke ali komponente. Z mešanjem oziroma prilagajanjem intenzivnosti posamezne komponente lahko poustvarimo širok nabor barv. Če je intenzivnost vseh treh komponent 0, to pomeni črno barvo (ni svetlobe). Vse preostale barve dobimo z mešanjem teh treh komponent. Treba je poudariti, da je barvni prostor RGB odvisen od naprave, ki reproducira dano vrednost RGB. V nasprotnem primeru, če so vse komponente prisotne v popolni intenzivnosti, dobimo belo barvo.

Barva v prostoru RGB je predstavljena kot trojček (r, g, b), sestavljen iz komponent, ki predstavljajo intenzivnost posamezne komponente RGB. Vsaka komponenta lahko vsebuje vse vrednosti od 0 pa do maksimalne določene vrednosti. Tu razlikujemo 3 različne formate:

- realno število od 0 do 1 (zapis s plavajočo vejico),
- zapis z odstotki od 0 do 100 odstotkov,
- 0 do 255 (8-bitno nepredznačeno število),
- 0 do 65,535 (16-bitno nepredznačeno število).

### 4.1.3 Barvni prostor HSV

Barvni prostor HSV in njemu podobni prostor HSL sta primera cilindrične reprezentacije točk v prostoru RGB. Njun namen je predstaviti bolj intuitiven barvni prostor za aplikacije, ki se ukvarjajo z računalniško grafiko, analizo slik in računalniškim vidom.

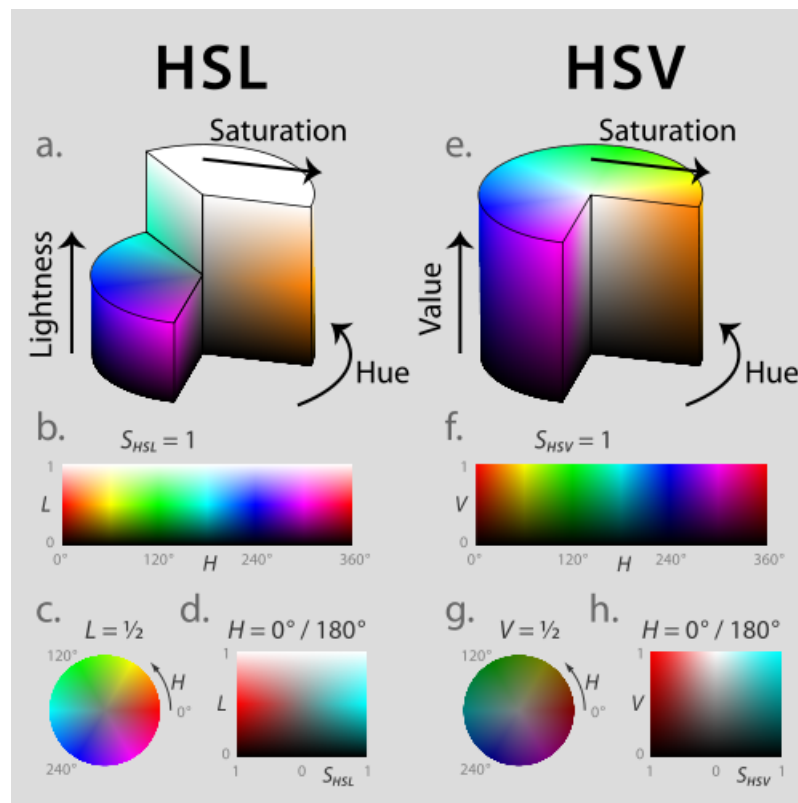
HSV je sestavljen iz treh komponent: odtenka (hue), nasičenosti (saturation), osvetlitve (value). Pogosto se za prostor HSV uporablja tudi sinonim HSB, pri katerem zadnja črka pomeni brightness (osvetlitev - op., isti prevod kot zgoraj za value). Prostoru HSV podoben pa je barvni prostor HSL. Od prostora HSV se razlikuje po zadnji komponenti - lightness (prevedeno kot svetlost). Razlika med osvetlitvijo (brightness) in svetlostjo (lightness) je, da je osvetlitev čiste barve enaka osvetlitvi bele barve, medtem ko je svetlost čiste barve enaka svetlosti sive barve. Grafična ponazoritev obeh opisanih prostorov je prikazana na sliki 4.1.

V cilindru vrtenje okrog centralne navpične osi predstavlja spremembo odtenka barve (hue), razdalja od centralne vertikalne osi predstavlja spremembo v nasičenosti barve (saturation), premikanje po dolžini te osi pa predstavlja spremembo osvetljenosti. Na tem mestu moramo poudariti, da je prostor HSV samo preslikava barvnega prostora RGB, ki je odvisen od naprave, zato se odtenki barv lahko razlikujejo med posameznimi napravami.


Poleg barvnega odtenka pri našem dojemanju barve igra pomembno vlogo nasičenost barve. Nasičenost barve je eden od izrazov, ki se uporabljajo za opisovanje intenzivnosti določene barve. Drugi izrazi vključujejo barvitost, kroma, čistost barve in intenzivnost. Ti izrazi se v literaturi pogosto uporabljajo izmenično, vendar se njihove definicije razlikujejo. Če želimo razumeti pojem nasičenosti barve, moramo najprej definirati koncept barvitosti slike. Barvitost pomeni razliko med barvo in sivino. Pojem nasičenosti barve je tesno povezan z barvitostjo, ponazarja namreč barvitost barve, ki je relativna glede na svojo osvetljenost. Vpliv nasičenosti barve je prikazan na sliki 4.2.

V knjižnici SimpleCV je nasičenost barve predstavljena kot vrednost od





Slika 4.1: Predstavitev barvnega prostora HSV in HSL.



Slika 4.2: Nasičenost barve - originalna slika na levi in njena kopija z 50 odstotki več barvne nasičenosti.



Slika 4.3: Vpliv pojemanja osvetlitve na dožemanje barve.

0 do 255.

Osvetljenost kot zadnja komponenta v prostoru HSV predstavlja količino svetlobe, ki jo oddaja ali odbija objekt. Manjša je osvetljenost, bolj dojemamo barvo kot črno, kar lahko vidimo na sliki 4.3. V knjižnici SimpleCV je nasičenost barve predstavljena kot vrednost od 0 do 255.

#### 4.1.4 Število barvnih odtenkov

Čeprav so profesionalne fotografije videti žive, pogosto uporabljajo malo barvnih odtenkov [15].

Za izračun števila barvnih odtenkov smo sliko najprej pretvorili v barvni prostor HSV. Izračunali smo histogram odtenkov barv z 20 stolpci, pri čemer smo upoštevali samo odtenke, katerih nasičenost z barvo presega 8,4 odstotka, hkrati pa tudi njihova osvetljenost presega 15 odstotkov. Za rezultat smo upoštevali samo stolpce, ki vsebujejo več kot 2 odstotka vseh pikslov na fotografiji. Primeri treh fotografij, ki se razlikujejo po številu barvnih odtenkov, in njihovi pripadajoči histogrami so prikazani na sliki 4.4.

#### 4.1.5 Povprečni odtenek

Za izračun povprečnega odtenka vzamemo že prej izračunan histogram odtenkov z 20 stolpci (4.1.4). Z enačbo 4.1 izračunamo povprečni odtenek barve  $\mu$ , pri čemer  $N$  predstavlja število stolpcev izračunanega histograma,  $x_k$  indeks stolpca,  $P(x_k)$  pa velikost stolpca v številu pikslov.

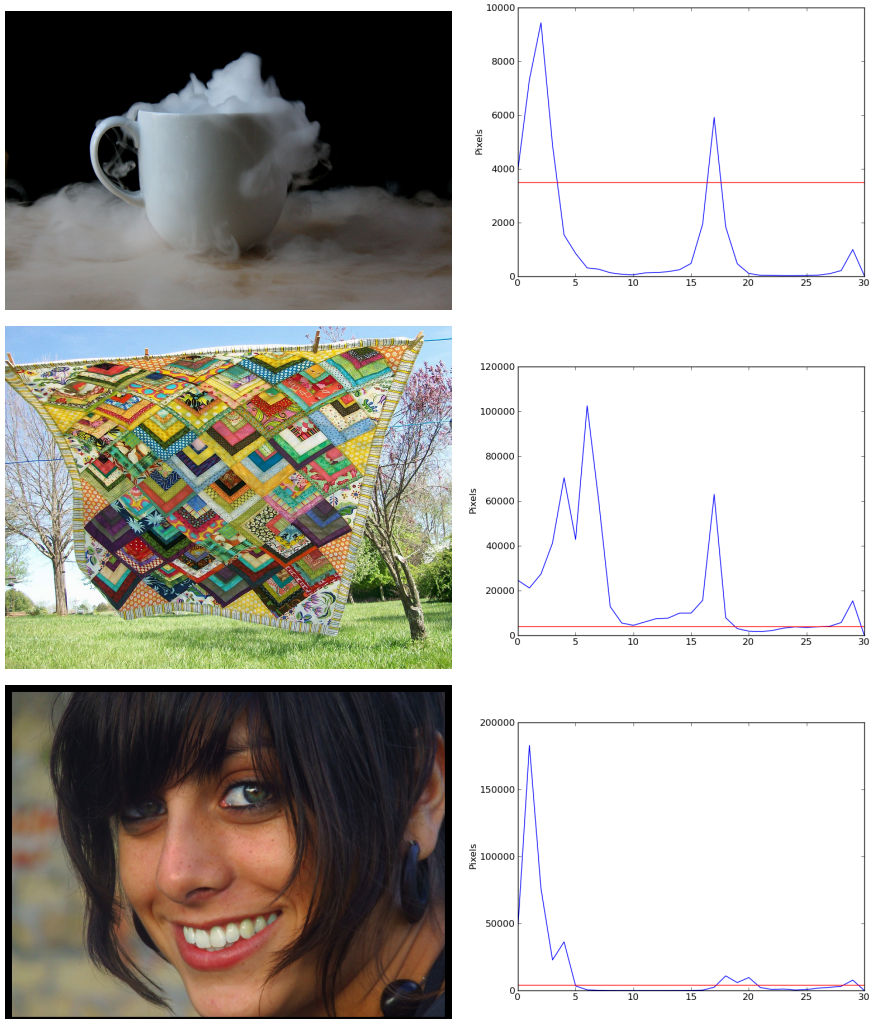
$$\mu = \frac{1}{N} \sum_{k=1}^N x_k P(x_k) \quad (4.1)$$

#### 4.1.6 Število barvnih vrhov

Identifikacije barvnih vrhov smo se lotili z uporabo metode, implementirane v knjižnici SimpleCV, ki temelji na programski kodi avtorja Elija Billauerja [3]. Metoda najprej izračuna histogram barvnih odtenkov, nato pa pri dani distribuciji poišče vse barvne vrhove. Metoda v nasprotju z naivnim pristopom pri identifikaciji vrhov ob pomoči prvega odvoda analizira vrednost krivulje levo in desno od potencialnega vrha, da izloči vse morebitne lažne vrhove.

#### 4.1.7 Barvna harmonija

V okviru analize barvne harmonije izračunamo 3 značilke, ki nam povedo, v kakšni relaciji so uporabljeni barvni odtenki. V ta namen izračunamo histogram barvnih odtenkov HSV z 9 stolpci. Da štejemo barvni odtenek za kredibilen, mora biti prisoten na 10 odstotkih pikslov fotografije.



Slika 4.4: Fotografije, ki se med seboj razlikujejo po številu barvnih odtenkov, za katere smo izračunali histogram barvnih odtenkov. Za potrebe te vizualizacije je bil izjemoma izračunan histogram s 30 stolpci. Horizontalna črta na histogramu predstavlja prag, od katerega dalje štejemo, da je barvni odtenek prisoten na fotografiji.

Prva značilka analizira sosednost barv, drugače rečeno, pove nam, ali so barve analogne. V našem primeru za sosednje barvne odtenke štejemo tiste odtenke, ki so v sosednjih stolpcih prej izračunanega histograma.

Druga značilka nam pove, ali fotografija vsebuje dve komplementarni barvi. Komplementarni sta barvi v primeru, da sta v krogu barvnih odtenkov na nasprotni strani tega kroga. V našem primeru barvni krog odtenkov predstavlja vrednost od 0 do 179, ki jo preslikamo na histogram z 9 stolpci. Kot komplementarni vzamemo barvi, ki sta v našem histogramu narazen vsaj za 3 stolpce. Posebno pozornost moramo nameniti temu, da je ta interval krožen, kar pomeni, da je v našem primeru barva v stolpcu 8 sosednja barvi v stolpcu 0.

Tretja značilka nam pove, ali fotografija vsebuje tri barvne odtenke, ki so v triadi. Tri barve so v triadi, kadar tvorijo trikotnik v barvnem krogu. Za naš izračun to pomeni, da zahtevamo, da so vsi barvni odtenki med seboj oddaljeni vsaj za 2 stolpca v že prej opisanem histogramu.

#### 4.1.8 Povprečna nasičenost barve (saturacija)

Izračunamo histogram HSV nasičenosti barve s 30 stolpci. Po enačbi 4.1 izračunamo povprečno nasičenost.

#### 4.1.9 Povprečna osvetlitev

Izračunamo histogram HSV osvetlitve s 30 stolpci. Po enačbi 4.1 izračunamo povprečno osvetlitev.

#### 4.1.10 Povprečna intenzivnost pikslov

Fotografijo najprej pretvorimo v sivinsko obliko. Nato izračunamo sivinski histogram s 30 stolpci. Po enačbi 4.1 izračunamo povprečno intenzivnost pikslov.

#### 4.1.11 Kontrast med subjektom in ozadjem

Kontrast fotografije ni enotno definiran pojem, običajno pa pomeni razliko med odtenkom barve in osvetljenostjo objekta v relaciji s preostalimi objekti. V našem primeru smo ga definirali kot zmnožek med razliko povprečnih odtenkov subjekta in ozadja in pa razliko med povprečno osvetlitvijo subjekta in ozadja. Isto lahko zapišemo tudi z enačbo 4.2, v kateri  $H_1$  in  $H_2$  predstavljata barvni odtenek,  $B_1$  in  $B_2$  pa osvetljenost. Tako pri razliki povprečnih odtenkov kot pri razliki povprečnih osvetlitev smo vzeli absolutno vrednost.

$$|H_1 - H_2| * |B_1 - B_2| \quad (4.2)$$

### 4.2 Proporci fotografije

#### 4.2.1 Proporci okvirja fotografije

Profesionalne fotografije imajo pogosto neobičajne proporce stranic, saj izkušeni fotografi pogosto naknadno spreminjajo okvir fotografije glede na izbrani motiv [14]. Zato nam ta enostavna značilka posredno nekaj pove o kvaliteti posnetka. Izračunamo tako proporce okvirja fotografije kot proporce stranic subjekta in razliko proporcev celotne slike in subjekta.

#### 4.2.2 Proporci subjekta in celotne slike

Kot smo omenili v poglavju 2, je za kvaliteten posnetek potreben izrazit motiv, kar obsega tudi njegovo relativno velikost glede na celotno fotografijo.

### 4.3 Kompozicija

Kot smo opisali v podpoglavju 2.2, kompozicija igra ključno vlogo pri estetski privlačnosti fotografije. Analizirali smo, koliko fotografija sledi različnim kompozicijskim pravilom. Ta pravila so: 1. pravilo tretjin, 2. zlato pravilo in 3. rabatment. V nadaljevanju smo združili rezultate pravila tretjin in zlatega

pravila v skupno značilko, ki daje najboljšo oceno kateregakoli pravila. Kot zadnje smo analizirali še prostorsko porazdelitev robov na fotografiji.

### 4.3.1 Pravilo tretjin

Pravilo tretjin, z dvema horizontalnima in dvema vertikalnima črtama, razdeli fotografijo na 9 enakovrednih pravokotnikov. Kot smo že omenili v poglavju 2.2, se pomembni elementi nahajajo vzdolž ene izmed teh črt. V našem primeru pričakujemo, da je ta pomemben element kar subjekt fotografije.

V začetku izračunamo:

- oddaljenost središča subjekta od vseh 4 črt, definiranih po pravilu tretjin,
- minimalno oddaljenost središča subjekta od katerekoli horizontalne črte,
- minimalno oddaljenost središča subjekta od katerekoli vertikalne črte,
- minimalno oddaljenost središča subjekta od katerekoli črte.

V nadaljevanju izračunamo oddaljenost subjekta od 4 napetostnih točk, definiranih po pravilu tretjin. Najprej izračunamo koordinate teh 4 točk, nato pa evklidsko razdaljo središča subjekta do najbližje napetostne točke. To razdaljo še normaliziramo glede na dolžino diagonale celotne fotografije.

Analizo sklenemo s konstrukcijo modela fotografije, ki sledi pravilu tretjin, podobno kot so to storili v delu [8]. Ta model kasneje uporabimo za primerjavo s fotografijo in na podlagi ujemanja določimo oceno kompozicije. Ponazoritev aplikacije modela na fotografijo lahko vidimo na sliki 4.5. Vzorec določa meje območij, ki se raztezajo na obeh straneh črt, definiranih po pravilu tretjin. Če je središče subjekta v predpisanih mejah območja, štejemo, da fotografija sledi pravilu kompozicije. Za izračun ocene modela kompozicije najprej izračunamo dve podoceni, ki ju kasneje združimo v končno oceno. Najprej izračunamo podoceno  $score_x$ , pri kateri  $dist_{xmax}$  predstavlja maksimalno oddaljenost od črte, ki jo še toleriramo po enačbah 4.3 in 4.4. Največje

možno odstopanje, ki ga toleriramo, je  $1/12$  širine fotografije. Parametra  $x_l$  in  $x_s$  pa po vrsti predstavljata koordinato x: 1. najbližje vertikalne črte in 2. središča subjekta fotografije. Enačba ima lastnost, da fotografiji, ki ima središče subjekta bližje eni izmed vertikalnih črt, podeli višjo oceno. Podobno po enačbah 4.5 in 4.6 izračunamo še podoceno  $score_y$ , pri kateri  $dist_{ymax}$  prav tako predstavlja maksimalno oddaljenost od črte, ki jo še toleriramo. Največje možno odstopanje, ki ga še toleriramo, je  $1/12$  višine fotografije. Parametra  $x_l$  in  $x_s$  pa tokrat predstavljata koordinato y: (1.) najbližje horizontalne črte in (2.) središča subjekta. Na podlagi teh dveh podocen konstruiramo dve različici modela. Prvo različico zanima samo bližina središča subjekta do najbližje vertikalne ali horizontalne črte in ne daje posebnega pomena napetostnim točkam. Zato kot rezultat vrne samo višjo izmed izračunanih ocen. Druga različica pa daje t. i. napetostnim točkam večji pomen. Kot rezultat vrača vsoto obeh podocen, to pa v praksi pomeni, da v primeru, da je središče subjekta na presečišču dveh črt, to se pravi na napetostni točki, vrne višji rezultat, kot bi ga sicer.

$$score_x = dist_{xmax} - |x_l - x_s|, \text{ kjer je } |x_l - x_s| < dist_{xmax} \quad (4.3)$$

$$score_x = 0, \text{ kjer je } |x_l - x_s| > dist_{xmax} \quad (4.4)$$

$$score_y = dist_{ymax} - |y_l - y_s|, \text{ kjer je } |y_l - y_s| < dist_{ymax} \quad (4.5)$$

$$score_y = 0, \text{ kjer je } |y_l - y_s| > dist_{ymax} \quad (4.6)$$

### 4.3.2 Zlato pravilo


Konstruirali smo dve horizontalni in dve vertikalni črti, ki delita sliko na dva dela v razmerju zlatega reza. Pričakujemo, da se središče subjekta nahaja vzdolž ene izmed teh črt.

V začetku izračunamo:





Slika 4.5: Ponazoritev aplikacije modela za analizo pravila tretjin na fotografijo.



Slika 4.6: Ponazoritev konstrukcije zlate spirale.

- oddaljenost središča subjekta od vseh 4 črt, definiranih po zlatem pravilu,
- minimalno oddaljenost središča subjekta od katerekoli horizontalne črte,
- minimalno oddaljenost središča subjekta od katerekoli vertikalne črte,
- minimalno oddaljenost središča subjekta od katerekoli črte.

V nadaljevanju izračunamo oddaljenost središča subjekta od 4 napetostnih točk, definiranih po zlatem pravilu. Najprej izračunamo koordinate teh 4 točk, nato pa izračunamo evklidsko razdaljo središča subjekta do najbližje napetostne točke. To razdaljo še normaliziramo glede na dolžino diagonale celotne fotografije.

Izračunamo tudi oddaljenost središča subjekta od začetne točke t. i. zlate spirale. Koordinate spirale izračunamo z delitvijo slike v zlatem razmerju  $1 : 1.61$ , dokler ni pravokotnik manjši od 1 piksla. Primer take spirale lahko vidimo na sliki 4.6. Možni začetni koordinati sta dve, zato kot rezultat upoštevamo minimalno evklidsko razdaljo središča subjekta do najbližje začetne točke. To razdaljo še normaliziramo glede na dolžino diagonale celotne fotografije.

Nazadnje pa kot že pri pravilu tretjin definiramo model, ki predstavlja fotografije, ki upoštevajo zlato pravilo. Ponazoritev aplikacije modela na



Slika 4.7: Ponazoritev aplikacije modela za analizo zlatega pravila na fotografijo.

fotografijo lahko vidimo na sliki 4.7. Način izračuna ocene modela je enak izračunu ocene modela iz razdelka 4.3.1, z razliko, da tokrat gledamo razdaljo od črt, definiranih po zlatem pravilu. Maksimalno odstopanje od črt, ki ga toleriramo, je tokrat 12,9 odstotka dolžine oziroma višine fotografije. Kot že pri pravilu tretjin konstruiramo 2 različici modela: 1. različico, ki t. i. napetostnim točkam ne daje posebnega pomena, in 2. različico, ki napetostnim točkam daje večji pomen.

### 4.3.3 Rabatment

Konstruirali smo dve horizontalni ali dve vertikalni črti (odvisno od razmerij proporcev fotografije), ki delita sliko na dva dela po pravilu rabatment. Pričakujemo, da se središče subjekta nahaja vzdolž ene izmed teh črt. Tako izračunamo oddaljenost središča subjekta od obeh črt kot tudi oddaljenost od najbližje črte. Kot značilko vključimo tudi podatek, ali gre za horizontalno ali za vertikalno delitev fotografije.

### 4.3.4 Splošna ocena kompozicije

Na podlagi ocen modelov, ki sta podlaga za oceno, koliko fotografija sledi pravilu tretjin ali zlatemu pravilu, definiramo značilko, ki predstavlja boljšo oceno obeh modelov. Poleg najboljše ocene zabeležimo še oznako modela, ki je vrnil to oceno. Obe značilki se pojavita v dveh različicah glede na to, katera modela uporabljata: 1. s preferiranjem napetostnih točk in 2. brez preferiranja napetostnih točk.

V okviru splošne ocene kompozicije izračunamo še razdaljo do najbližje črte, definirane po kateremkoli zgoraj definiranem pravilu.

### 4.3.5 Oddaljenost stranic subjekta od robov okvirja fotografije

Na fotografiji običajno ni zaželeno, da bi bil motiv blizu robov okvirja posnetka. Zato izračunamo oddaljenost subjekta od vseh štirih robov.

### 4.3.6 Prostorska porazdelitev robov slike

Kot smo že omenili, ni zaželeno, da so motiv ali pomembnejši elementi blizu robov slike. Sliko smo iz zapisa RGB pretvorili v sivinski zapis in tako sliko zgladili z Gaussovim jedrom velikosti  $3 \times 3$ . S pomočjo detektorja robov Canny smo izračunali sliko z označenimi robovi. Nato pa smo za vsak piksel na sliki, ki predstavlja rob, izračunali razdaljo do najbližjega roba okvirja fotografije. Te razdalje smo sešteli in jih normalizirali s številom vseh pikslov na fotografiji. Tako smo dobili značilko, ki predstavlja oddaljenost zaznanih robov od okvirja fotografije.

Nato pa smo problem obrnili in ga definirali kot oddaljenost robov od središča fotografije. Uporabili smo že prej izračunano sliko z označenimi robovi, nato pa smo za vsak piksel na fotografiji, ki predstavlja rob, izračunali evklidsko razdaljo do središča slike. Izračunane razdalje smo sešteli in normalizirali s številom vseh pikslov na fotografiji.

Zabeležili smo tudi vsoto pikslov, ki so označeni kot rob, in jo normalizirali s številom vseh pikslov na fotografiji.

V nadaljevanju smo podobno kot že pri pravilu tretjin in zlatem pravilu definirali model, ki predstavlja fotografije z robovi, zaznanimi z detektorjem robov, ki se nahajajo blizu okvirja fotografije. S pomočjo enačb 4.7 in 4.8 izračunamo oceno modela  $score$ , pri kateri  $dist_{max}$  predstavlja maksimalno oddaljenost zaznanega roba od najbližjega roba okvirja, ki jo še toleriramo. Največje možno odstopanje, ki ga toleriramo, je  $1/5$  širine (višine v primeru zgornjega in spodnjega roba) fotografije. Parametra  $pos_f$  in  $pos_e$  pa po vrsti predstavljata koordinato x (ali y v primeru zgornjega in spodnjega roba): 1. najbližjega roba okvirja in 2. zaznanega roba. Enačba ima lastnost, da fotografiji, ki ima zaznan rob bliže robu okvirja fotografije, podeli višjo oceno.

$$score = dist_{max} - |pos_f - pos_e|, \text{ kjer je } |pos_f - pos_e| < dist_{max} \quad (4.7)$$

$$score = 0, \text{ kjer je } |pos_f - pos_e| > dist_{max} \quad (4.8)$$

## 4.4 Vizualna kompleksnost

Da bi ugotovili, kako kompleksna je fotografija, potrebujemo način merjenja vizualne kompleksnosti. Vizualno kompleksnost bi lahko drugače definirali tudi kot najkrajši način za opis umetniškega dela. Dober približek vizualne kompleksnosti je kar velikost kompresirane datoteke fotografije [4]. Fotografije smo zato shranili v formatu JPEG in kot rezultat vzeli njihovo velikost v kB. Shranili smo jih v njihovi originalni velikosti, saj bi v nasprotnem primeru lahko izgubili del informacije.

Prav tako pa smo za značilko vizualne kompleksnosti upoštevali tudi število pikslov, ki jih vrne detektor robov. Značilka je podrobneje opisana v razdelku 4.3.6.



## Poglavje 5

# Zajem učnih podatkov

Za preizkus v poglavju 4 opisanih značilk smo izvedli dva eksperimenta v dveh različnih naborih fotografij. Prvi eksperiment je vključeval fotografije s spletnega portala Flickr, ki so jih ocenili izkušeni fotografi. Subjekt teh fotografij je bil identificiran ročno, pravtako s pomočjo izkušenih fotografov. Izbrali smo fotografije, ki so bile pred kratkim naložene na portal, in pa fotografije, ki so jih uredniki označili kot izbiro dneva. Izbrane fotografije so bile različnih tipov. Podroben opis postopka zajema učnih podatkov za potrebe prvega eksperimenta je predstavljen v naslednjem podpoglavju.

Ročna identifikacija subjekta je dolgotrajna, zato je pridobivanje večje učne množice težavno. Iz tega razloga je bila učna množica za potrebe prvega eksperimenta razmeroma majhna. Samodejno razpoznavanje subjekta fotografije pa je zahtevna naloga s področja računalniškega vida, ki sega na področje interpretacije slik, zato se ga v okviru naše naloge nismo odločili implementirati. Ker smo želeli naše značilke preizkusiti na večji učni množici, smo ta problem obšli tako, da smo za drugi eksperiment uporabili fotografije portretov s fotografskega portala DPChallenge [1]. V tem primeru je bilo mogoče za identifikacijo subjekta uporabiti kar detektor obrazov, za kar obstajajo zanesljive metode na področju računalniškega vida [20]. Te fotografije so bile prav tako že ocenjene, saj so bile del fotografskih tekmovanj. Podroben opis postopka zajema učne množice za potrebe drugega

eksperimenta je opisan v podpoglavju 5.2.

## 5.1 Nabor fotografij za prvi eksperiment

Za pridobitev učnih podatkov smo za pomoč zaprosili izkušene fotografe. Zajema učnih podatkov smo se lotili z izdelavo enostavne spletne aplikacije, in sicer s pomočjo spletnega ogrodja Django, javascript knjižnice jQuery in podatkovne zbirke MySQL. Aplikacija je fotografu omogočila enostavno označevanje subjekta, če je ta seveda obstajal, s pravokotno regijo na fotografiji. Nato je podal še ocene fotografije, in sicer glede na vnaprej definirane parametre (slika 5.1).

V želji po globljem razumevanju problema smo se odločili, da poleg splošne ocene fotografije povprašamo še po bolj podrobnih parametrih, ki definirajo estetiko fotografije. Prav tako pa smo s povpraševanjem po podrobnih parametrih želeli doseči večjo objektivnost pri ocenjevanju slik. V želji po čim bolj konsistentnih rezultatih smo omejili nabor ocen na tri možne vrednosti: slaba, povprečna, dobra.

Parametri in njihov nabor ocen, po katerih smo spraševali, so bili poleg splošne ocene še:

- kompozicija (slaba, povprečna, dobra),
- barvna paleta (slaba, povprečna, dobra),
- osvetlitev (slaba, povprečna, dobra),
- ostrina fotografije (slaba, povprečna, dobra),
- razločljivost motiva (slaba/ni motiva, povprečna, dobra).

Pri zajemu učnih podatkov smo seveda želeli ustvariti čim večjo zbirko označenih in ocenjenih fotografij glede na naše zmožnosti. Prav tako smo zaradi kredibilnosti težili k cilju, da ima vsaka fotografija vsaj 3 ocene. Ker je ocenjevanje fotografij, še posebno pa označevanje subjekta časovno potratno





**Kompozicija:**  
☐ slaba ☐ povprečna ☐ dobra

**Barvna paleta:**  
☐ slaba ☐ povprečna ☐ dobra

**Osvetlitev:**  
☐ slaba ☐ povprečna ☐ dobra

**Ostrina slike:**  
☐ slaba ☐ povprečna ☐ dobra

**Splošna ocena slike:**  
☐ slaba ☐ povprečna ☐ dobra

**Razločljivost motiva:**  
☐ slaba / ni motiva ☐ povprečna ☐ dobra

**Motiv**  
x koordinata:  y koordinata:  dolžina:  širina:  [Reset](#)

Slika 5.1: Zaslonski posnetek spletne aplikacije za označevanje in ocenjevanje fotografij.

opravilo, bi bila ocena celotne zbirke fotografij prevelik zalogaj za enega samega uporabnika. Zato nismo vztrajali pri zahtevi, da fotograf označi vse slike v zbirki, ampak smo se zadovoljili s pogojem, da ima vsaka fotografije 3 ocene različnih ocenjevalcev.

Za ocenjevanje smo uporabili fotografije s spletnega portala Flickr. Izbrali smo fotografije, ki so bile pravkar naložene na portal ("recently uploaded"). Tem fotografijam smo zaradi slabe kvalitete dodali slike iz kategorije "pick of the day". Z ročno selekcijo smo nato izločili med seboj preveč podobne fotografije in pa abstraktne fotografije. To smo storili zaradi enostavnosti in želje, da bi naš sistem uporabili v realnem svetu, in sicer za pomoč uporabnikom, ki niso vešči fotografiranja. Ker smo želeli dobiti uravnoteženo učno zbirko, smo se po opozorilu fotografov o slabi kvaliteti teh fotografij odločili, da vključimo tudi fotografije "picks of the day", ki so bistveno boljše kvalitete.

Vrstni red fotografij, ki so jih ocenjevali fotografi, je bil naključen. Tako smo preprečili monotonost, saj bi ocenjevanje po vrstnem redu (glede na to, kdaj smo fotografije dodali) lahko pripeljalo do tega, da bi fotografi ocenjevali več slik istega tipa zapored. Ta monotonost bi imela za posledico manjšo pozornost in tako tudi manj objektivne rezultate. Prav tako je grozila nevarnost daljšega zaporedja fotografij nizke oziroma visoke kvalitete, kar bi lahko imelo za posledico prilagoditev kriterijev ocenjevalca navzdol ali navzgor, to pa bi pripeljalo do nekonsistentnih rezultatov. Pozorni smo bili tudi na potencialno utrujenost fotografov zaradi dolgotrajnega ocenjevanja. Zato smo omogočili, da lahko fotograf prekine ocenjevanje in fotografije oceni v več sejah.

Ob zavedanju, da se želene lastnosti fotografije razlikujejo glede na tip in namen, smo fotografije naknadno ročno razvrstili v posamezne kategorije. Vseh kategorij je bilo 14 in so skupaj s številom slik v posamezni kategoriji prikazane v spodnji tabeli 5.1.

V naši zbirki fotografij je 274 fotografij, ocenilo pa jih je 14 izkušenih fotografov. Od tega ima 258 fotografij vsaj 3 ocene. Povprečna ocena fotografije je bila 2,14. Število ocenjenih fotografij na ocenjevalca in njihova povprečna ocena sta prikazana v tabeli 5.2. Zaradi varovanja podatkov smo

tip fotografije	št. slik	povprečna ocena
živali	14	2.33
arhitektura	12	2.11
črno & bela	13	2.51
vozila	8	1.73
mestna panorama	7	2.82
close up	33	1.95
rože	11	2.49
notranjost	23	1.89
pokrajina & narava	47	2.47
ljudje & prireditve	32	1.81
portreti	36	2.39
šport	17	1.69
podvodo	10	1.54
urbano	11	1.95

Tabela 5.1: Tipi fotografij in število fotografij posameznega tipa.


ocenjevalec	št.ocenjenih slik	povprečna ocena
oc1	275	2,10
oc2	14	2,07
oc3	5	1,60
oc4	107	2,04
oc5	40	2,30
oc6	9	1,67
oc7	22	2,09
oc8	38	1,89
oc9	71	2,32
oc10	96	2,27
oc11	81	1,79
oc12	40	1,88
oc13	174	2,39
oc14	9	1,67

Tabela 5.2: Število ocenjenih slik, ki jih je ocenil posamezni ocenjevalec, skupaj s povprečno skupno oceno. Ocenjevalci so za skupno oceno izbirali med možnostmi: slabo (1), povprečno (2), dobro (3).


njihova imena nadomestili z zaporedno številko ocenjevalca. Kot zanimivost prilagamo tudi nekaj primerov tako najboljših (slika 5.2) kot najslabših fotografij (slika 5.3).

## 5.2 Nabor fotografij za drugi eksperiment

V želji po večji učni množici glede na prvi eksperiment smo pri drugem eksperimentu za učno množico uporabili fotografije portretov s fotografskega portala DPChallenge. Pri teh fotografijah smo se izognili zamudnemu ročnemu določanju subjekta fotografije, tako da smo za identifikacijo subjekta uporabili detektor obrazov. Pridobljene fotografije so bile del fotografskih



Slika 5.2: Nekaj fotografij iz naše zbirke, ki so dobile najboljše ocene.



Slika 5.3: Nekaj fotografij iz naše zbirke, ki so dobile najslabše ocene.

ocena	št. fotografij
1 - 2	0
2 - 3	13
3 - 4	324
4 - 5	3500
5 - 6	9310
6 - 7	4344
7 - 8	367
8 - 9	7
9 - 10	0


Tabela 5.3: Porazdelitev ocen fotografij portretov s portala DPChallenge.

tekmovanj in so bile ocenjene z naborom ocen od 1 do 10. Vsega skupaj smo pridobili 17 865 fotografij s povprečno oceno fotografije 5,55. Porazdelitev ocen fotografij je podana v tabeli 5.3. Ker smo si kot cilj zadali razlikovati med dobrimi in slabimi fotografijami, smo se odločili za učno množico izbrati zgornjih 20 in spodnjih 20 odstotkov najbolje ocenjenih fotografij. Vendar pa smo naknadno z analizo porazdelitve ocen fotografij ugotovili, da ocene močno težijo k povprečju. Pri odločitvi za zgornjih in spodnjih 20 odstotkov najbolje ocenjenih fotografij bi bila ločnica med visoko- in nizkokvalitetnimi posnetki preprosto premajhna. Zato smo sprejeli odločitev, da obravnavamo fotografije z oceno manj kot 4,5 kot nizkokvalitetne in fotografije z oceno več kot 6,5 kot visokokvalitetne. Vztrajali smo tudi pri pogoju, da ima vsaka fotografija vsaj 100 glasov. Tako smo dobili 2 575 fotografij (14 odstotkov prvotne zbirke), od tega 1 109 fotografij nizke kvalitete in 1 466 fotografij visoke kvalitete. Primere najboljših in najslabših fotografij prikazujeta slika 5.4 in slika 5.5.

Zavoljo lažje detekcije obrazov ter lažjega načrtovanja in implementacije značilk smo se omejili na portrete z enim obrazom. Tako smo ročno izločili vse fotografije z več obrazi. Prav tako smo izločili vse fotografije, na katerih



Slika 5.4: Nekaj fotografij iz naše zbirke, ki so dobile najboljše ocene.



Slika 5.5: Nekaj fotografij iz naše zbirke, ki so dobile najslabše ocene.



ni bila vidna vsaj polovica obraza. Po izločitvi neustreznih fotografij nam je ostalo 1 649 fotografij.


V naslednjem koraku smo z detektorjem obrazov določili subjekt fotografije. Uporabili smo detektor obrazov Haar iz knjižnice OpenCV, katerega implementacija temelji na detektorju Viola-Jones [20]. Detekcija obrazov na našem naboru fotografij se je izkazala za precej težavno, saj je bila podvržena precejšnji napaki. Detektorji obrazov predpostavljajo bolj ali manj enakomerno osvetlitev obraza z minimalnim zakrivanjem, medtem ko umetniška fotografija pogosto kot izrazno sredstvo uporablja kontrastno osvetlitev. Obrazi na fotografijah so bili tako pogosto zakriti z različnimi objekti, osvetlitev je bila neenakomerna, obrazi rotirani. Primer takega obraza je prikazan na sliki 5.6. Problem slabe detekcije smo reševali z uporabo petih različnih kaskad, ki jih ponuja knjižnica OpenCV. Štiri izmed kaskad so bile uporabljene za frontalno detekcijo in ena za detekcijo obraza iz profila. Kaskade so skupaj z uporabljenimi parametri podane v tabeli 5.4. Ponazoritev detekcije obrazov z uporabo vseh 5 kaskad prikazuje slika 5.7. Podatke o detektiranih obrazih vsake izmed uporabljenih kaskad smo kasneje uporabili kot vhodne podatke za algoritem za izbor najbolj verjetnega obraza. Algoritem je za vsak detektiran obraz izračunal oceno in na koncu kot rezultat izbral obraz z najvišjo oceno. Ocena (score) je bila izračunana po formuli 5.1, v kateri *rel\_size* predstavlja velikost detektiranega obraza v razmerju s celotno sliko, *weight* predstavlja utež, ki smo jo določili kaskadi in jo lahko razberemo iz tabele 5.4, *rect\_count* pa predstavlja število detektiranih obrazov, ki se prekrivajo z obrazom za katerega se računa ocena. Algoritem je imel tudi eno izjemo, in to v primeru, da kaskada, ki zaznava obraze iz profila, vrne največji obraz. V tem primeru je ta obraz samodejno rezultat algoritma brez upoštevanja ocen preostalih detekcij. Kljub vsemu pa je detekcija uspela samo na 1 048 fotografijah od skupno 1 649 fotografij (na 64 odstotka vseh fotografij).

$$score = rel\_size + weight + rect\_count \quad (5.1)$$




ime kaskade	skalirni faktor	min št. sosedov
frontalface_default	1.05	6
frontalface_alt	1.05	3
frontalface_alt2	1.05	3
frontalface_alt_tree	1.05	3
profileface	1.05	3

Tabela 5.4: Imena uporabljenih deskriptorjev kaskad skupaj s parametri uporabljenimi za detekcijo.



Slika 5.6: Primer fotografije obraza, pri kateri ni bila uspešna nobena izmed izvedenih detekcij obrazov.



Slika 5.7: Prikaz uspešne detekcije obrazov z uporabo vseh petih kaskad Haar.

## Poglavje 6

### Rezultati

V okviru našega dela smo definirali množico značilk, ki opisujejo različne vidike fotografije. Za preizkus teh značilk smo izvedli 2 eksperimenta v dveh različnih naborih fotografij. V prvem eksperimentu smo klasificirali fotografije s spletnega portala Flickr glede na parametre, po katerih smo predhodno spraševali fotografe. Ti parametri so bili splošna ocena, uporabljena barvna paleta in kompozicija. Pokazalo se je, da je samodejno določanje estetike fotografij mogoče v tem naboru fotografij. Pri izvedbi strojnega učenja smo ob uporabi klasifikatorja SVM dosegli klasifikacijsko natančnost 95 odstotkov, ko smo fotografije klasificirali glede na splošno oceno, ki so jo za nas poprej določili izkušeni fotografi. Dobre rezultate smo prav tako dobili pri klasifikaciji teh fotografij glede na oceno kompozicije (87 odstotkov) in oceno uprabljene barvne sheme (95 odstotkov).

Pri prvem eksperimentu smo subjekt fotografije identificirali ročno, kar se je izkazalo za zamudno, zato je bila učna množica sorazmerno majhna. Pri drugem eksperimentu pa smo ta problem obšli tako, da smo izbrali fotografije portretov, pri katerih smo subjekt fotografije določili z detektorjem obrazov. Fotografije v tem naboru so bile del fotografskih tekmovanj in so mejile na umetniško fotografijo. Samodejno določanje estetike fotografij v tem naboru fotografij se je izkazalo za težavnejše, a smo še vedno dobili pozitivne rezultate. Pri izvedbi strojnega učenja smo ob uporabi klasifikatorja SVM dosegli

klasifikacijsko natančnost 75 odstotkov, ko smo fotografije klasificirali glede na oceno uporabnikov portala.

Za strojno učenje smo uporabili metode Naivni Bayes, klasifikacijsko drevo in klasifikator SVM. Metodo Naivni Bayes smo izbrali kot primer enostavnega algoritma za strojno učenje. Poleg enostavnosti pa s pomočjo nomograma, ki nam je na voljo ob uporabi te metode, lahko ocenimo tudi kvaliteto izračunanih značilk. Kot drugo metodo smo izbrali klasifikacijsko drevo predvsem zaradi enostavnosti interpretacije rezultatov. Kot zadnjo metodo smo vzeli klasifikator SVM, ki smo ga uporabili za primerjavo prejšnjih dveh algoritmov z metodo, ki v večini primerov daje najboljše rezultate. V rezultatih je mogoče opaziti še klasifikator Majority, ki vse primere klasificira v večinski razred, in se uporabi za primerjavo kot spodnja meja za sprejemljivo klasifikacijsko natančnost.

Pri metodi Naivni Bayes smo uporabili privzete nastavitve, ki nam jih ponudi programsko orodje Orange. Za predhodno verjetnost (prior) smo uporabili relativno frekvenco, velikost okna LOESS je bila 0,5 s številom vzorčnih točk, nastavljenih na 100. Pri klasifikacijskem drevesu je bil kriterij za izbor atributov "information gain", izbrali pa smo opcijo za iskanje optimalnega reza (search for optimal split). Minimalno število primerov v listih smo nastavili na 2 in izvedli rezanje drevesa s privzeto nastavljenim m-estimate. Za klasifikator SVM smo uporabili jedro RBF, pri katerem smo knjižnici sami dopustili, da poišče optimalne vrednosti parametrov 'Cost' in 'Complexity bound' za model.

Klasifikacijske metode smo testirali z desetkratnim prečnim preverjanjem. Kot rezultate prilagamo klasifikacijsko točnost in površino pod krivuljo ROC (AUC). Kot glavno merilo za ocenjevanje kvalitete vhodnih atributov (značilk) smo uporabili metriko reliefF.

## 6.1 Prvi eksperiment

Za prvi eksperiment smo uporabili fotografije s portala Flickr, ki so jih ocenili izkušeni fotografi. Subjekt teh fotografij je bil identificiran ročno, prav tako ob pomoči izkušenih fotografov. Podroben postopek pridobivanja teh podatkov je opisan v prejšnjem poglavju. Za učno množico smo vzeli samo fotografije, ki so izpolnjevale naše pogoje za kredibilno oceno fotografije. Ti pogoji so bili: 1. obstajajo vsaj 3 ocene iste fotografije, 2. nobena ocena se od ostalih ne razlikuje za več kot en nivo in 3. večina ocen je v soglasju. Eksperiment smo razdelili na tri podeksperimente. V prvem podeksperimentu fotografije klasificiramo glede na splošno oceno, v drugem glede na oceno kompozicije in v tretjem glede na oceno uporabljenih barvne palete. Rezultate teh treh podeksperimentov predstavljamo v nadaljevanju.

### 6.1.1 Splošna ocena

Izkušeni fotografi so podali splošno oceno fotografije, katere nabor je bil: 1. slaba, 2. povprečna in 3. dobra. Na podlagi zgoraj opisanih pogojev smo dobili učno množico, ki je vsebovala 192 fotografij, za katere smo bili prepričani, da je ta ocena kredibilna. Ker je bil naš cilj razlikovati med visoko- in nizkokvalitetnimi posnetki, smo izločili vse fotografije, ocenjene s splošno oceno povprečno. Tako smo dobili učno množico velikosti 114 fotografij, ki pa je bila zelo neenakomerno porazdeljena. Problem neenakomerne porazdelitve smo rešili tako, da smo v učni množici podvojili primere fotografij, ocenjene s splošno oceno slabo. Tako smo dobili 74 primerov fotografij z oceno slabo (49 odstotkov vseh fotografij) in 77 primerov fotografij z oceno dobro (51 odstotkov vseh fotografij).

Za klasifikacijo smo uporabili 72 v poglavju 4 opisanih značilk. Od tega ima kar 57 značilk pozitivno vrednost metrike  $\text{reliefF}$ . V želji, da ne bi prenaučili našega klasifikatorja, smo se odločili izbrati minimalen nabor značilk, pri katerem dosežemo čim boljšo klasifikacijsko natančnost. Tako smo izbrali 28 značilk z najboljšo vrednostjo metrike  $\text{reliefF}$  (tabela 6.1), ki smo jih

uporabili za strojno učenje (tabela 6.2). Tabela, v kateri so predstavljene vse pri klasifikaciji uporabljene značilke s pripadajočo metriko  $\text{reliefF}$ , informacijskim prispevkom in razmerjem informacijskega prispevka, je priložena v dodatku A (tabela A.1).

### 6.1.2 Kompozicija fotografije

Podobno kot pri prvem podeksperimentu smo tudi oceno kompozicije pridobili s pomočjo izkušenih fotografov. Nabor ocen je bil: 1. slaba, 2. povprečna in 3. dobra. Uporabili smo iste kriterije za kredibilno oceno in izločili primere, ki so bili ocenjeni z oceno povprečno. Prav tako smo dobili neenakomerno porazdelitev ocen, kar smo ponovno reševali s podvojitvijo učnih primerov, označenih z oceno slabo. Tako smo dobili 56 primerov fotografij z oceno slabo (35,4 odstotka vseh fotografij) in pa 102 primera fotografij z oceno dobro (64,6 odstotka vseh fotografij).

Za klasifikacijo smo uporabili 43 v poglavju 4 opisanih značilk, ki analizirajo kompozicijo fotografije. Po analizi značilk smo ugotovili, da ima 16 teh značilk pozitivno vrednost metrike  $\text{reliefF}$ . Ker po našem mnenju ni bilo nevarnosti, da bi model prenaučili, smo izbrali vseh teh 16 značilk (tabela 6.3) in jih uporabili za strojno učenje (tabela 6.4). Tabela, v kateri so predstavljene vse pri klasifikaciji uporabljene značilke s pripadajočo metriko  $\text{reliefF}$ , informacijskim prispevkom in razmerjem informacijskega prispevka, je priložena v dodatku A (tabela A.2).

### 6.1.3 Uporabljena barvna paleta

Podobno kot pri prejšnjih dveh podeksperimentih smo tudi oceno uporabljene barvne palete pridobili s pomočjo izkušenih fotografov. Nabor ocen je bil: 1. slaba, 2. povprečna in 3. dobra. Uporabili smo iste kriterije za kredibilno oceno in izločili primere, ki so bili ocenjeni z oceno povprečno. Prav tako smo dobili neenakomerno porazdelitev ocen, kar smo ponovno reševali s podvojitvijo učnih primerov, označenih z oceno slabo. Tako smo dobili

#	značilka	reliefF	IG	razmerje IG
1	contrast_subj_bg (4.1.11)	0.171	0.141	0.168
2	saturation_avg_subj (4.1.8)	0.054	0.305	0.072
3	saturation_avg_whole (4.1.8)	0.044	0.184	0.043
4	thirds_rule_min_v (4.3.1)	0.041	0.102	0.074
5	brightness_avg_diff (4.1.9)	0.034	0.226	0.053
6	offset_top (4.3.5)	0.033	0.263	0.070
7	intensity_avg_diff (4.1.10)	0.032	0.167	0.039
8	hues_count_diff (4.1.4)	0.027	0.092	0.035
9	edges_center_sum (4.3.6)	0.026	0.087	0.020
10	comp_best_score_rule (4.3.4)	0.026	0.032	0.022
11	comp_best_score_rule_no_pp (4.3.4)	0.026	0.032	0.022
12	hues_avg_diff (4.1.5)	0.025	0.196	0.046
13	subj_relative_size (4.2.2)	0.025	0.147	0.044
14	peaks_count_whole (4.1.6)	0.024	0.048	0.022
15	edges_score (4.3.6)	0.024	0.144	0.033
16	golden_rule_min_v (4.3.2)	0.022	0.089	0.048
17	brightness_avg_subj (4.1.9)	0.022	0.076	0.041
18	peaks_count_diff (4.1.6)	0.021	0.078	0.037
19	thirds_rule_score_no_pp (4.3.1)	0.021	0.200	0.091
20	offset_left (4.3.5)	0.020	0.220	0.059
21	edges_pixel_count (4.3.6)	0.020	0.102	0.024
22	peaks_count_bg (4.1.6)	0.020	0.052	0.022
23	hues_count_subj (4.1.4)	0.019	0.089	0.034
24	comp_best_score_no_pp (4.3.4)	0.019	0.172	0.055
25	edges_borders_sum (4.3.6)	0.018	0.190	0.044
26	offset_bottom (4.3.5)	0.016	0.177	0.048
27	golden_rule_score_no_pp (4.3.2)	0.016	0.111	0.037
28	brightness_avg_bg (4.1.9)	0.015	0.249	0.067

Tabela 6.1: Seznam 28 najboljših značilk, s pripadajočo metriko reliefF, informacijskim prispevkom IG in razmerjem informacijskega prispevka (razmerje IG), ki smo jih preizkusili na naboru fotografij s portala Flickr na podlagi splošne ocene. V oklepaju je zapisana številka razdelka, v katerem je bila značilka predstavljena.

	CA	AUC
Naivni Bayes	0.65	0.76
Večinski klasifikator	0.51	0.50
klasifikacijsko drevo	0.71	0.77
klasifikator SVM	0.95	0.96

Tabela 6.2: Rezultati klasifikacije fotografij iz nabora Flickr glede na splošno oceno z uporabo 28 najboljših značilk. Kratica CA označuje klasifikacijsko natančnost, AUC pa površino pod krivuljo ROC.

32 primerov fotografij z oceno slabo (28,8 odstotka vseh fotografij) in 79 primerov fotografij z oceno dobro (71,2 odstotka vseh fotografij).

Za klasifikacijo smo uporabili 29 v poglavju 4 opisanih značilk, ki analizirajo uporabljeno barvno paletu fotografije. Po analizi značilk smo ugotovili, da ima 15 teh značilk pozitivno vrednost metrike reliefF. Izbrali smo 14 najboljših značilk po metriki reliefF (tabela 6.5) in jih uporabili za strojno učenje (tabela 6.6). Tabela, v kateri so predstavljene vse pri klasifikaciji uporabljene značilke s pripadajočo metriko reliefF, informacijskim prispevkom in razmerjem informacijskega prispevka, je priložena v dodatku A (tabela A.3).

## 6.2 Drugi eksperiment

Za potrebe drugega eksperimenta smo uporabili fotografije portretov s fotografskega portala DPChallenge [1], pri katerih smo za identifikacijo subjekta uporabili detektor obrazov. Te fotografije so bile prav tako že ocenjene, saj so bile del fotografskih tekmovanj. Podroben postopek pridobivanja teh fotografij je opisan v prejšnjem poglavju. Kot smo opisali v prejšnjem poglavju, smo fotografije, ki so bile ocenjene z naborom ocen od 1 do 10, razdelili v dve kategoriji: 1. visokokvalitetne in 2. nizkokvalitetne fotografije. Nabor fotografij je obsegal 1 048 fotografij, od tega je 648 fotografij spadalo v



#	značilka	reliefF	IG	razmerje IG
1	offset_top (4.3.5)	0.138	0.130	0.134
2	offset_left (4.3.5)	0.118	0.214	0.142
3	golden_rule_score_no_pp (4.3.2)	0.072	0.193	0.066
4	comp_best_score (4.3.4)	0.064	0.090	0.092
5	comp_best_score_no_pp (4.3.4)	0.064	0.090	0.092
6	golden_rule_score (4.3.2)	0.043	0.207	0.070
7	rabatment_dist_type (4.3.3)	0.018	0.000	0.000
8	rabatment_dist_2 (4.3.3)	0.007	0.227	0.056
9	thirds_rule_min_v (4.3.1)	0.006	0.116	0.125
10	aspect_ratio_subj (4.2.1)	0.003	0.265	0.061
11	comp_min_dist_rule (4.3.4)	0.003	0.009	0.010
12	aspect_ratio (4.2.1)	0.002	0.139	0.037
13	offset_bottom (4.3.5)	0.001	0.123	0.133
14	comp_best_score_rule (4.3.4)	0.001	0.070	0.047
15	comp_best_score_rule_no_pp (4.3.4)	0.001	0.070	0.047
16	offset_right (4.3.5)	0.000	0.123	0.133

Tabela 6.3: Seznam 14 najboljših značilk, s pripadajočo metriko reliefF, informacijskim prispevkom IG in razmerjem informacijskega prispevka (razmerje IG), ki smo jih preizkusili na naboru fotografij s portala Flickr na podlagi ocene kompozicije. V oklepaju je zapisana številka razdelka, v katerem je bila značilka predstavljena.

	CA	AUC
Naivni Bayes	0.74	0.80
Večinski klasifikator	0.65	0.50
klasifikacijsko drevo	0.73	0.80
klasifikator SVM	0.87	0.93

Tabela 6.4: Rezultati klasifikacije fotografij iz nabora Flickr glede na oceno kompozicije z uporabo 16 najboljših značilnk. Kratica CA označuje klasifikacijsko natančnost, AUC pa površino pod krivuljo ROC.

#	značilka	reliefF	IG	razmerje IG
1	saturation_avg_subj (4.1.8)	0.317	0.286	0.213
2	hues_are_analog (4.1.7)	0.090	0.033	0.036
3	saturation_avg_whole (4.1.8)	0.082	0.341	0.083
4	hues_count_diff (4.1.4)	0.035	0.074	0.028
5	hues_count_subj (4.1.4)	0.033	0.095	0.039
6	hues_count_whole (4.1.4)	0.033	0.085	0.033
7	peaks_count_whole (4.1.6)	0.025	0.112	0.051
8	intensity_avg_diff (4.1.10)	0.019	0.262	0.062
9	intensity_avg_subj (4.1.10)	0.015	0.114	0.065
10	contrast_subj_bg (4.1.11)	0.014	0.290	0.075
11	brightness_avg_diff (4.1.9)	0.008	0.338	0.082
12	saturation_avg_bg (4.1.8)	0.006	0.254	0.068
13	contrast_subj_whole (4.1.11)	0.006	0.056	0.032
14	saturation_avg_diff (4.1.8)	0.004	0.227	0.056

Tabela 6.5: Seznam 14 najboljših značilnk, s pripadajočo metriko reliefF, informacijskim prispevkom IG in razmerjem informacijskega prispevka (razmerje IG), ki smo jih preizkusili na naboru fotografij s portala Flickr na podlagi ocene uporabljene barvne palete. V oklepaju je zapisana številka razdelka, v katerem je bila značilka predstavljena.

	CA	AUC
Naivni Bayes	0.7553	0.8318
Večinski klasifikator	0.7121	0.5000
klasifikacijsko drevo	0.8652	0.9193
klasifikator SVM	0.9545	1.0000

Tabela 6.6: Rezultati klasifikacije fotografij iz nabora Flickr glede na oceno uporabljene barvne palete z uporabo 14 najboljših značilk. Kratica CA označuje klasifikacijsko natančnost, AUC pa površino pod krivuljo ROC.

kategorijo visokokvalitetnih fotografij (61,8 odstotka vseh fotografij), 400 pa v kategorijo nizkokvalitetnih fotografij (38,2 odstotka fotografij). Rezultate klasifikacije v te dve kategoriji predstavljamo v nadaljevanju.

Za klasifikacijo smo uporabili 71 v poglavju 4 opisanih značilk. Od tega ima kar 67 značilk pozitivno vrednost metrike reliefF. V želji, da ne bi prenaučili našega klasifikatorja, smo se odločili izbrati minimalen nabor značilk, pri katerem dosežemo čim boljšo klasifikacijsko natančnost. Tako smo izbrali 41 značilk z najboljšo vrednostjo metrike reliefF (tabela 6.7), ki smo jih uporabili za strojno učenje (tabela 6.8). Tabela, v kateri so predstavljene vse pri klasifikaciji uporabljene značilke s pripadajočo metriko reliefF, informacijskim prispevkom in razmerjem informacijskega prispevka, je priložena v dodatku A (tabela A.4).

#	značilka	reliefF	IG	razmerje IG
1	edges_score (4.3.6)	0.195	0.111	0.086
2	edges_pixel_count (4.3.6)	0.149	0.054	0.046
3	edges_center_sum (4.3.6)	0.108	0.065	0.045
4	edges_borders_sum (4.3.6)	0.079	0.089	0.076
5	hues_count_whole (4.1.4)	0.055	0.040	0.013
6	hues_count_bg (4.1.4)	0.054	0.045	0.015
7	peaks_count_whole (4.1.6)	0.048	0.008	0.004
8	subj_relative_size (4.2.2)	0.047	0.021	0.005

**Tabela 6.7 – se nadaljuje iz prejšne strani**

#	značilka	reliefF	IG	razmerje IG
9	peaks_count_bg (4.1.6)	0.045	0.011	0.004
10	brightness_avg_bg (4.1.9)	0.041	0.052	0.012
11	brightness_avg_whole (4.1.9)	0.041	0.061	0.014
12	peaks_count_subj (4.1.6)	0.040	0.005	0.002
13	hues_are_analog (4.1.7)	0.038	0.007	0.011
14	hues_count_subj (4.1.4)	0.037	0.022	0.008
15	saturation_avg_bg (4.1.8)	0.036	0.011	0.003
16	hues_avg_subj (4.1.5)	0.035	0.021	0.005
17	intensity_avg_whole (4.1.10)	0.034	0.049	0.012
18	size_kb (4.4)	0.034	0.129	0.030
19	intensity_avg_bg (4.1.10)	0.033	0.053	0.012
20	hues_avg_diff (4.1.5)	0.032	0.029	0.007
21	golden_rule_min_v (4.3.2)	0.031	0.011	0.003
22	saturation_avg_whole (4.1.8)	0.028	0.013	0.003
23	offset_bottom (4.3.5)	0.028	0.013	0.003
24	rabatment_dist_type (4.3.3)	0.028	0.000	0.000
25	hues_count_diff (4.1.4)	0.028	0.028	0.021
26	hues_avg_whole (4.1.5)	0.027	0.028	0.007
27	hues_avg_bg (4.1.5)	0.025	0.028	0.007
28	comp_best_score_no_pp (4.3.4)	0.023	0.011	0.003
29	saturation_avg_diff (4.1.8)	0.023	0.013	0.003
30	brightness_avg_subj (4.1.9)	0.021	0.049	0.012
31	peaks_count_diff (4.1.6)	0.019	0.015	0.007
32	offset_right (4.3.5)	0.018	0.006	0.001
33	comp_min_dist (4.3.4)	0.018	0.005	0.002
34	comp_best_score (4.3.4)	0.017	0.011	0.003
35	intensity_avg_diff (4.1.10)	0.017	0.024	0.006
36	aspect_ratio (4.2.1)	0.017	0.062	0.015
37	golden_rule_score_no_pp (4.3.2)	0.017	0.015	0.004

	CA	AUC
Naivni Bayes	0.72	0.79
Večinski klasifikator	0.62	0.50
klasifikacijsko drevo	0.69	0.64
klasifikator SVM	0.75	0.79

Tabela 6.8: Rezultati klasifikacije fotografij portretov s portala DPChallenge glede na oceno uporabnikov portala z uporabo 41 najboljših značilk. Kratica CA označuje klasifikacijsko natančnost, AUC pa površino pod krivuljo ROC.

**Tabela 6.7 – se nadaljuje iz prejšne strani**

#	značilka	reliefF	IG	razmerje IG
38	rabatment_dist_2 (4.3.3)	0.016	0.019	0.004
39	contrast_subj_bg (4.1.11)	0.016	0.015	0.005
40	brightness_avg_diff (4.1.9)	0.016	0.019	0.004
41	hues_are_complem (4.1.7)	0.015	0.000	0.001

Tabela 6.7: Seznam 41 najboljših značilk, s pripadajočo metriko reliefF, informacijskim prispevkom IG in razmerjem informacijskega prispevka (razmerje IG), ki smo jih preizkusili na naboru fotografij portretov s portala DPChallenge. V oklepaju je zapisana številka razdelka, v katerem je bila značilka predstavljena.

## 6.3 Diskusija rezultatov

V tem podglavju bomo predstavili vpliv in intepretacijo značilk, ki smo jih uporabili za izvedbo strojnega učenja in katerih rezultati so predstavljeni v tem poglavju. Pri analizi vpliva značilk smo uporabljali predvsem metriko re-

lieF, manj pa tudi informacijski prispevek oziroma na njem temelječe razmerje informacijskega prispevka. Za vplivne značilke smo šteli vse značilke s pozitivno vrednostjo metrike relieF. Analizo vpliva značilk smo opravili na podlagi obeh opravljenih eksperimentov. Za namen interpretacije značilk smo uporabljali predvsem nomogram klasifikatorja Naivni Bayes, pomagali smo si tudi z različnimi vizualizacijami, ki jih ponuja programsko orodje Orange. Značilke smo interpretirali predvsem na podlagi podeksperimenta, pri katerem smo fotografije klasificirali glede na njihovo splošno oceno (prvi eksperiment), in na podlagi nabora fotografij iz drugega eksperimenta. V nadaljevanju bomo predstavili vpliv teh značilk po kategorijah iz poglavja 4.

### 6.3.1 Barvna shema

V okviru analize uporabljene barvne palete predstavljamo rezultate vpliva in interpretacijo za:

- število barvnih odtenkov,
- povprečni odtenek,
- število barvnih vrhov,
- barvno harmonijo,
- povprečno nasičenost barve,
- povprečno osvetlitev,
- povprečno intenzivnost pikslov,
- kontrast med subjektom in ozadjem.

Značilke, ki opisujejo število barvnih odtenkov, so se konsistentno izkazale za ustrezne, z izjemo značilke, ki podaja število barvnih odtenkov na ozadju fotografije. Ta značilka se ni izkazala pri klasifikaciji na podlagi uporabljene barvne sheme in splošne ocene pri prvem eksperimentu. Izkazale pa so se

značilke, ki računajo: 1. število barvnih odtenkov na subjektu, 2. število barvnih odtenkov na celotni fotografiji in 3. razliko uporabljenih barvnih odtenkov na subjektu in ozadju fotografije. Iz nomograma klasifikatorja Naivni Bayes pri drugem eksperimentu smo ugotovili, da se verjetnost za kvalitetno fotografijo zmanjšuje z naraščanjem števila barvnih odtenkov na celotni fotografiji na vrednost večjo od 4,02. Optimalno število odtenkov, pri katerih je bila verjetnost za kvalitetno fotografijo največja, sta bila 2 odtenka. To se je še bolj izrazito pokazalo pri subjektu fotografije, pri katerem je bila največja verjetnost za pozitivno fotografijo 2,5 odtenka, verjetnost pa se je začela močno zmanjševati, ko se je število barvnih odtenkov povzpelo na vrednost 3,1. Podobno se je izkazalo tudi pri ozadju fotografije. Verjetnost za kvalitetno fotografijo se je začela močno zmanjševati pri vrednosti 3,85, največja verjetnost pa je bila pri vrednosti 2. Tako se je potrdila teorija, da imajo kvalitetne fotografije malo barvnih odtenkov.

Značilke, ki opisujejo povprečen barvni odtenek, so se izkazale v naboru fotografij portretov v drugem eksperimentu. To so bile značilke, ki so povprečen odtenek računale na subjektu, na ozadju, in na celotni sliki ter razliko med povprečnim odtenkom subjekta in ozadja. V prvem eksperimentu se je pri klasifikaciji na podlagi splošne ocene izkazala samo razlika med povprečnim odtenkom subjekta in ozadja. Pri prvem eksperimentu smo opazili, da se verjetnost za kvalitetno fotografijo zmanjšuje pri povečevanju razlike med povprečnim odtenkom subjekta in ozadja na vrednost, večjo od 0,67. Ta vrednost predstavlja razdaljo med stolpci histograma barvnih odtenkov, ki je bil izračunan na 20 stolpcev.

Pri vseh eksperimentih se je izkazala značilka, ki podaja število vrhov barvnih odtenkov na celotni fotografiji. Prav tako so se povsod, razen pri klasifikaciji na podlagi uporabljene barvne palete v prvem eksperimentu, izkazale značilke, ki izračunajo število vrhov barvnih odtenkov na subjektu in na ozadju in razliko med številom vrhov barvnih odtenkov subjekta in ozadja. Podobno kot pri značilkah, ki podajajo število barvnih odtenkov, smo pri drugem eksperimentu ugotovili, da se verjetnost za kvalitetno fo-

tografijo zmanjšuje z naraščanjem števila barvnih vrhov odtenkov na celotni fotografiji na vrednost, večjo od 3,36. Podobno smo ugotovili za število barvnih vrhov odtenkov, uporabljenih v ozadju fotografije. Verjetnost za kvalitetno fotografijo se začne zmanjševati pri vrednosti 3,64. Prav tako smo iz nomograma razbrali, da se verjetnost za kvalitetno fotografijo povečuje, kadar je razlika med vrhovi barvnih odtenkov subjekta in ozadja večja od 1,2. Na podlagi tega se potrjuje teorija, da so zaželeni bolj enostavna ozadja.

Pri analizi barvne harmonije je nekaj uspeha dosegla značilka, ki pove, ali je uporabljena barvna paleta analogna. Ta značilka se je obnesla pri klasifikaciji na podlagi uporabljene barvne palete v prvem eksperimentu in pri naboru fotografij v drugem eksperimentu. Dober rezultat te značilke se je skladal z rezultati razlike med povprečnim barvnim odtenkom subjekta in ozadja, ki je znašala samo 0,67 (manj kot en stolpec razlike v histogramu). Značilki, ki dajeta informacijo o tem, ali je barvni sestav komplementaren ali pa tvori triado, se nista obnesli. Razlog za slabši vpliv teh značilk je bil predvsem v majhnem informacijskem prispevku. Po našem mnenju bi se bolje obnesla značilka, ki bi dajala informacijo o tem, ali uporabljena barvna paleta sledi kateremu izmed ustaljenih barvnih sestavov.

Zelo dobre rezultate smo dobili pri analizi vpliva nasičenosti barve. Tukaj se konsistentno dobro izkažejo prav vse značilke. Kljub vsemu smo opazili nekaj variacije pri velikosti vpliva v prvem in drugem eksperimentu. V prvem eksperimentu se za bolj vplivno izkažeta značilki, ki računata povprečno nasičenost barve na subjektu in na celoti. V drugem eksperimentu pa se bolje izkažeta značilki, ki podajata povprečno nasičenost ozadja in pa razliko povprečne nasičenosti med subjektom in ozadjem.

Tudi značilke, ki računajo povprečno osvetljenost, so se izkazale za uspešne pri klasifikaciji na podlagi splošne ocene v prvem eksperimentu in pri naboru fotografij iz drugega eksperimenta. V vseh eksperimentih pa se izkaže za uspešno značilka, ki podaja razliko v osvetljenosti med subjektom in ozadjem.



Pri značilkah, ki opisujejo intenzivnost pikslov, se pri vseh eksperimentih izkažeta značilki, ki podajata intenzivnost pikslov subjekta in razliko med intenzivnostjo pikslov subjekta in ozadja. Značilki, ki opisujeta intenzivnost pikslov celotne fotografije in ozadja, nista konsistentni.

Značilka, ki podaja kontrast med subjektom in ozadjem, se je izkazala za ustrezno glede na metriko  $\text{relief}$ , a vendar z različnimi vrednostmi med opravljenimi eksperimenti.

### 6.3.2 Proporci fotografije

V okviru analize proporcev fotografije smo si ogledali:

- proporce okvirja fotografije
- in relativno velikost subjekta v primerjavi s celotno sliko.

Za ustrezno se je izkazala značilka, ki opisuje proporce okvirja fotografije. Uspešna je bila pri klasifikaciji na podlagi kompozicije v prvem eksperimentu in pri naboru fotografij portretov v drugem eksperimentu. Pri naboru fotografij portretov v drugem eksperimentu smo zaznali, da je verjetnost za kvalitetno fotografijo največja v intervalu od 0,81 do 1,2. Medtem pa so imele fotografije, ki so uporabljale bolj ekstremne proporce, manjšo verjetnost, da spadajo med kvalitetne fotografije. Proporci subjekta so bili izračunani samo na fotografijah v prvem eksperimentu, saj je bil v drugem eksperimentu subjekt določen s kvadratno regijo na fotografiji, ki je rezultat detektorja obrazov. V obeh primerih, ko je bilo izračunano to razmerje, smo zaznali minimalni vpliv.

Vpliv relativne velikosti stranic subjekta glede na celotno fotografijo je bilo mogoče zaznati pri vseh eksperimentih razen pri klasifikaciji na podlagi kompozicije, vendar se vrednosti razlikujejo po analizah.

### 6.3.3 Kompozicija

V okviru analize kompozicije fotografije smo si ogledali:

- zlato pravilo,
- pravilo tretjin,
- najboljšo oceno na podlagi zgornjih dveh pravil,
- rabatment,
- oddaljenost subjekta od stranic fotografij,
- analizo prostorske porazdelitve robov.

Pri analizi zlatega pravila sta se najboljše izkazali dve značilki: 1. značilka, ki podaja oceno kompozicije na podlagi modela fotografije, ki sledi zlatemu rezu (različica, ki ne preferira napetostnih točk), in 2. značilka, ki podaja razdaljo do najbližje vertikalne črte, definirane po zlatem pravilu. Prva značilka se je izkazala za uspešno pri vseh eksperimentih. Tudi druga značilka se je izkazala za uspešno pri klasifikaciji na podlagi splošne ocene v prvem eksperimentu in pri naboru portretov v drugem eksperimentu, ne pa tudi pri klasifikaciji na podlagi kompozicije v prvem eksperimentu. Preostale značilke niso pokazale večjega vpliva, prav tako ne značilka, ki je opisovala najkrajšo razdaljo središča subjekta od središča zlate spirale. Izkazala se ni niti značilka, ki je podajala razdaljo do najbližje napetostne točke, definirane po pravilu zlatega reza. Verjetnost za kvalitetno fotografijo počasi narašča pri vrednostih ocene modela kompozicije (brez preferiranja napetostnih točk) nad 10,82 pri prvem eksperimentu. Iz nomograma pri klasifikaciji na podlagi splošne ocene pa lahko vidimo, da verjetnost za kvalitetno fotografijo narašča, ko je oddaljenost središča subjekta od najbližje vertikalne črte, definirane po zlatem pravilu manjša od 11 odstotkov celotne širine.

V vseh eksperimentih se, podobno kot že pri zlatem pravilu, za uspešno izkaže značilka, ki podaja razdaljo do najbližje vertikalne črte, definirane po pravilu tretjin. Prav tako pa se pri klasifikaciji na podlagi splošne ocene v prvem eksperimentu in pri naboru fotografij iz drugega eksperimenta za uspešno izkaže značilka, ki podaja oceno kompozicije na podlagi modela fotografije, ki sledi pravilu tretjin (tudi v tem primeru različica, ki ne preferira

napetostnih točk). Iz nomograma pri klasifikaciji na podlagi splošne ocene iz prvega eksperimenta lahko vidimo, da verjetnost za kvalitetno fotografijo narašča, ko je oddaljenost središča subjekta od najbližje vertikalne črte, definirane po pravilu tretjin, manjša od 15 odstotkov celotne širine. Iz istega nomograma razberemo tudi, da se verjetnost dobre fotografije povečuje linearno s povečevanjem ocene modela kompozicije po pravilu tretjin nad 5,07 (model, ki ne preferira napetostnih točk).

V nadaljevanju smo si ogledali značilko, ki združi rezultate obeh zgoraj omenjenih modelov za analizo kompozicije. Po pričakovanjih se značilka, ki podaja višjo izmed podanih ocen kompozicije, izkaže za vplivno pri vseh treh eksperimentih. Uporabili smo najboljšo oceno kompozicije modelov, ki ne preferirata napetostnih točk. Značilka, ki preferira napetostne točke, pa se obnese slabše. Iz nomograma pri klasifikaciji na podlagi splošne ocene fotografij razberemo, da se verjetnost za kvalitetno fotografijo povečuje linearno z vrednostjo ocene več kot 5,7. Prav tako se obnese značilka, ki označuje kompozicijski model, ki je podal višjo oceno. Poleg združevanja rezultatov kompozicijskih modelov smo si ogledali tudi značilko, ki podaja razdaljo do najbližje črte, definirane po enem izmed zgornjih pravil. Ta značilka se obnese pri klasifikaciji na podlagi splošne ocene v prvem eksperimentu in pri fotografijah portretov v drugem eksperimentu. Z njo pa je povezana značilka, ki podaja kompozicijsko pravilo, ki je bilo uporabljeno pri izračunu te razdalje. Izkaže se za podobno uspešno. Iz nomograma pri drugem eksperimentu razberemo, da se verjetnost za kvalitetno fotografijo povečuje, ko upada vrednost značilke pod 0,02. Povedano drugače, ko je oddaljenost središča fotografije od najbližje črte, definirane po enem izmed uporabljenih kompozicijskih pravil, manjša od 2 odstotkov je verjetnost za kvalitetno fotografijo večja. Vpliv teh dveh združenih značilk je bil malo manjši od vpliva značilk, ki opisujejo zlato pravilo, zato sklepamo, da naš način združevanja ocen kompozicij ni bil optimalen.

Značilke, ki opisujejo pravilo rabatment, so bile uspešne pri nekaterih naborih fotografij, vendar se niso izkazale za konsistentne v vseh opravljenih

eksperimentih. V naboru fotografij portretov pri drugem eksperimentu se za uspešno izkaže značilka, ki podaja razdaljo od četrte imaginarne stranice drugega impliciranega kvadrata po pravilu rabatment. To je kvadrat, ki si deli vertikalno stranico z desnim robom okvirja slike (ali s spodnjim robom okvirja fotografije, kadar je višina večja od širine fotografije). Pri oddaljenosti središča subjekta fotografije od četrte imaginarne stranice od 27 odstotkov do 70 odstotkov celotne širine (ali višine) dobimo pozitivno verjetnost za kvalitetno fotografijo. To pomeni, da se preferirajo fotografije, pri katerih je subjekt na desni ali spodnji polovici fotografije. Po primerjavi z rezultati odmikov središča subjekta od robov fotografije, ki jih opisujemo v nadaljevanju, to lahko trdimo samo za desno polovico fotografije.

Značilke, ki opisujejo oddaljenost središča subjekta od stranic fotografij, so se izkazale za ustrezne v vseh eksperimentih razen pri oddaljenosti od zgornjega roba okvirja, ki se presenetljivo ni izkazala pri naboru fotografij portretov v drugem eksperimentu. Pri fotografijah portretov se izkaže, podobno kot smo že ugotovili v prejšnjem odstavku, da obstaja pozitivna verjetnost za kvalitetno fotografijo, kadar je subjekt na desni polovici fotografije. Preferirajo se odmiki središča subjekta od levega okvirja roba za več kot 38 odstotkov in odmiki od desnega roba okvirja od 28 odstotkov do 10 odstotkov celotne širine fotografije. Prav tako smo ugotovili, da so bolj zaželenе fotografije, pri katerih je subjekt v zgornji polovici fotografije. Verjetnost za kvalitetno fotografijo se je povečevala, ko je bila oddaljenost središča subjekta od spodnjega roba večja od 23 odstotkov, pa vse do 86 odstotkov celotne višine fotografije.

Vse značilke, ki analizirajo prostorsko porazdelitev robov, se izkažejo za zelo vplivne pri klasifikaciji na podlagi splošne ocene v prvem delu in pri naboru fotografij iz drugega eksperimenta, ne pa tudi pri klasifikaciji na podlagi kompozicije. Pri naboru fotografij portretov v drugem eksperimentu opazimo, da se večje število detektiranih robov ujema z večjo verjetnostjo za kvalitetno fotografijo. Ta verjetnost se povečuje, ko je odstotek zaznanih robov v primerjavi s celotno fotografijo večji od 7,14 odstotka. Nadalje ugo-

tavljamo, da je verjetnost za kvalitetno fotografijo večja za fotografije, ki imajo vsoto oddaljenosti detektiranih robov od najbližjega roba fotografije večjo od 5,57. Podobno se pokaže tudi pri vsoti oddaljenosti detektiranih robov od središča fotografije. Tu se pokaže, da za fotografije, ki imajo to vsoto večjo od 15,21, obstaja večja verjetnost, da spadajo med kvalitetne fotografije. Nekoliko presenetljivo pa se podobna značilnost pokaže tudi pri oceni modela prostorske porazdelitve robov, ki ga uporabljamo za primerjavo, kako blizu so zaznani robovi fotografije z robovi okvirja fotografije. Ta model daje višje ocene fotografijam, katerih robovi so blizu okvirja fotografije. Razlog za ta pojav je po našem mnenju ta, da se preferirajo fotografije z večjim številom zaznanih robov. Ob večjem številu zaznanih robov se tudi vsota, ki je rezultat modela, poveča. Podobne lastnosti, vendar z drugimi vrednostmi opazimo tudi pri klasifikaciji na podlagi splošne ocene fotografij v prvem eksperimentu.

#### 6.3.4 Vizualna kompleksnost

Za uspešno se izkaže tudi velikost datoteke v kB, ki smo jo preizkusili samo pri naboru fotografij v drugem eksperimentu. V tem primeru opazimo čisto linearno odvisnost velikosti datoteke in verjetnosti, da gre za kvalitetno fotografijo. Verjetnost za kvalitetno fotografijo se povečuje z vrednostjo značilke nad 101,42 kB, pri čemer je bila povprečna velikost slike 340 694 pikslov. Izkazala pa se je tudi že prej opisana značilka, ki podaja število pikslov, ki jih kot rezultat vrne detektor robov Canny. Ta značilka se je izkazala pri vseh eksperimentih. Iz danih rezultatov lahko potrdimo, da vizualna kompleksnost vpliva na zaznavo kvalitete fotografije.

#### 6.3.5 Primerjava rezultatov z deli drugih avtorjev

Rezultate prvega eksperimenta, v katerem smo značilke preizkušali na naboru fotografij s portala Flickr, bi lahko primerjali z delom Bhattacharya et al [2]. Podobno kot mi so se zanašali na definicijo subjekta s pomočjo uporabnika.

Njihovo učno množico so sestavljale fotografije dveh vrst: 1. fotografije z izrazitim osprednjim objektom in 2. fotografije pokrajine in morja, ki nimajo izrazitega osprednjega objekta. V tem delu so avtorji dosegli klasifikacijsko natančnost 86 odstotkov pri klasifikaciji estetike fotografij v 4 razrede. Za primerjavo je naš klasifikator dosegel 95-odstotno natančnost pri razlikovanju med 2 razredoma: 1. nizko- in 2. visokokvalitetno fotografijo. Glede na klasifikacijsko natančnost smo dosegli 9-odstotno izboljšanje glede na njihovo delo, vendar smo za klasifikacijo uporabili samo 2 razreda.

Rezultate drugega eksperimenta, v katerem smo preizkušali značilke na fotografijah portretov s portala DPChallenge, bi lahko primerjali z rezultati dela avtorjev Ke et al [15]. Avtorji omenjenega dela so, tako kot mi, za učne podatke vzeli fotografije s portala DPChallenge. Za klasifikacijo so izbrali 10 odstotkov najboljših in 10 odstotkov najslabših fotografij. Podobno kot mi so upoštevali samo fotografije z vsaj 100 ocenami. Pri teh učnih podatkih so dosegli 72-odstotno klasifikacijsko natančnost. Naš klasifikator pa je na fotografijah portretov z istega portala dosegel 75-odstotno klasifikacijsko natančnost, kar pomeni 3-odstotno izboljšanje glede na njihovo delo.

## Poglavje 7

### Sklepne ugotovitve

Izbira estetsko najprivlačnejših fotografij je ob današnji poplavi fotografij zamudno opravilo, zato bi si želeli opravilo avtomatizirati. V okviru našega dela smo identificirali lastnosti fotografij, ki vplivajo na zaznavo estetske kvalitete fotografije, in na njihovi podlagi definirali lahko izračunljive značilke. Vsega skupaj smo definirali in implementirali 73 značilk, ki analizirajo barvno shemo, kompozicijo, proporce in vizualno kompleksnost fotografije. Večina teh značilk je bila odvisna od identifikacije subjekta fotografije. Te značilke smo preizkusili na dveh naborih fotografij. Za potrebe prvega eksperimenta smo pridobili fotografije s spletnega portala Flickr, ki so jih za nas ocenili izkušeni fotografi. Subjekt teh fotografij je bil identificiran ročno, prav tako ob pomoči izkušenih fotografov. Pokazalo se je, da je samodejno določanje estetike fotografij mogoče v tem naboru fotografij. Pri izvedbi strojnega učenja smo ob uporabi klasifikatorja SVM dosegli 95-odstotno klasifikacijsko natančnost, ko smo fotografije klasificirali glede na splošno oceno, ki so jo poprej določili izkušeni fotografi. Tako smo za 9 odstotkov izboljšali klasifikacijsko natančnost glede na primerljivo delo v literaturi.

Ker je ročna identifikacija subjekta dolgotrajna, je pridobivanje večje učne množice težavno, zato je bila učna množica za potrebe prvega eksperimenta sorazmerno majhna. Želeli pa smo si naše značilke preizkusiti na večji učni množici, tako da smo za drugi eksperiment uporabili fotografije portretov s

fotografskega portala DPChallenge [1]. V tem primeru smo za identifikacijo subjekta uporabili detektor obrazov, saj računalniški vid zagotavlja dokaj zanesljivo detekcijo obrazov. Fotografije v tem naboru so bile del fotografskih tekmovanj in so mejile na umetniško fotografijo. Samodejno določanje estetike fotografij v tem naboru fotografij se je izkazalo za težavnejše, a smo še vedno dobili pozitivne rezultate. Pri izvedbi strojnega učenja smo ob uporabi klasifikatorja SVM dosegli 75-odstotno klasifikacijsko natančnost, ko smo fotografije klasificirali glede na oceno uporabnikov portala. Tako smo za 3 odstotke izboljšali klasifikacijsko natančnost glede na primerljivo delo v literaturi. Slabšo natančnost pri klasifikaciji fotografij portretov pripisujemo predvsem lastnostim nabora fotografij. Fotografije s portala DPChallenge so bile del fotografskih tekmovanj in so mejile na umetniško fotografijo, te fotografije pa so bistveno težje za klasifikacijo in so izven okvira našega dela. Svoje doda tudi dejstvo, da je bila razlika med razredoma, uporabljenima za klasifikacijo, nizka. Pri naboru ocen od 1 do 10 in povprečni vrednosti 5,5 smo za nizkokvalitetne fotografije vzeli vse fotografije pod oceno 4,5 in podobno za visokokvalitetne fotografije vse fotografije nad oceno 6,5.

Pomemben del naše naloge je bila identifikacija značilnk, ki so uporabne za samodejno ocenjevanje estetike fotografij. Vpliv značilnk, uporabljenih v obeh eksperimentih, smo ocenili s pomočjo metrike  $\text{reliefF}$  in podali njihovo interpretacijo na podlagi nomograma klasifikatorja Naivni Bayes in vizualizacij, ki jih ponuja programsko orodje Orange. Z opravljeno analizo vpliva značilnk in interpretacijo vrednosti teh značilnk smo objektivno potrdili estetski pomen vsaj nekaterih značilnk, ki jih uporabljamo predvsem izkustveno, in ne analitično, saj takrat, ko ocenjujemo fotografijo, običajno ne razmišljamo o vrednostih posameznih značilnk, ampak je naš pristop bolj celosten.

Na podlagi naših eksperimentov lahko potrdimo, da kvalitetne fotografije uporabljajo malo barvnih odtenkov, čeprav so pogosto videti žive. Prav tako uporabljajo barvno enostavna ozadja, saj tako zagotavljajo, da subjekt izstopa na fotografiji in ga tako lažje zaznamo. Pomembna je tudi kompozicija fotografije, za kar imamo na voljo več kompozicijskih pravil ali smernic, kot so



pravilo tretjin, zlato pravilo in rabatment. V naših eksperimentih smo odkrili, da je ne glede na uporabljeno pravilo kompozicije najpomembnejša umestitev subjekta glede na horizontalno os okvirja fotografije (s predpostavko, da ima fotografija ležeč format okvirja). Nadalje ugotavljamo, da se ekstremni proporci okvirja fotografije ne izkažejo za zaželene. Ugotavljamo pa tudi, da so zaželene vizualno bolj kompleksne fotografije, pri čemer je kompleksnost fotografije treba razumeti v smislu kompleksnosti subjekta.

V nadaljnjem delu bi bilo smiselno implementirati splošno metodo za samodejno prepoznavanje subjekta fotografije. V našem delu smo pri prvem eksperimentu subjekt fotografije identificirali ročno, kar se je izkazalo za zamudno, zato je bilo pridobivanje učne množice oteženo. Pri drugem eksperimentu pa smo ta problem obšli tako, da smo izbrali fotografije portretov, pri katerih smo subjekt fotografije določili z detektorjem obrazov. Razpoznavanje subjekta fotografije je zahtevna naloga s področja računalniškega vida, ki sega na področje interpretacije slik, zato se ga v okviru naše naloge za Prešernovo nagrado nismo dotaknili. Lahko pa bi prepoznavanje subjekta reševali ob pomoči različnih hevristik, kot smo to že storili pri fotografijah portretov. V okviru zaznavanja subjekta bi lahko določili tudi tip fotografije in tako definirali tudi značilke, ki so lastne samo določeni podmnožici tipov fotografij, kot sta na primer pokrajinska fotografija in ulična fotografije. Primer take značilke bi bila višina obzorja pri slikah krajine in morja.



# Literatura

- [1] DPChallenge - A Digital Photography Contest. Dostopno na: <http://www.dpchallenge.com/>.
- [2] S. Bhattacharya, R. Sukthankar, M. Shah. "A framework for photo-quality assessment and enhancement based on visual aesthetics", *Proceedings of the international conference on Multimedia*, MM '10, New York, NY, USA, 2010, str. 271–280.
- [3] E. Billauer – Peak detection using matlab. Dostopno na: <http://billauer.co.il/peakdet.html>.
- [4] G. Birkin, "Aesthetic Complexity: Practice and Perception in Art & Design", doktorska disertacija, Nottingham Trent University, 2010.
- [5] M. Boutell, J. Luo, "Bayesian fusion of camera metadata cues in semantic scene classification", *2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, Washington, D.C., USA, 2004, str. 623–630.
- [6] G. Bradski, A. Kaehler, "Learning OpenCV", O'Reilly Media Inc., 2008.
- [7] K. E. Burchett, "Color harmony", *Color Research & Application*, št. 27, zv. 1, str. 28–31, 2002.
- [8] S. S. Khan, D. Vogel, "Evaluating visual aesthetics in photographic portraiture", *Proceedings of the Eighth Annual Symposium on Compu-*

- tational Aesthetics in Graphics, Visualization, and Imaging*, Annecy, France, 2012, str. 55–62
- [9] T. Curk, J. Demšar, Q. Xu, G. Leban, U. Petrovič, I. Bratko, G. Shaulsky, B. Zupan, “Microarray data mining with visual programming”, *Bioinformatics*, št. 21, zv. 3, str. 396–398, feb. 2005.
- [10] R. Datta, D. Joshi, J. Li, and J.Z. Wang, “Studying aesthetics in photographic images using a computational approach”, *Proceedings of the 9th European conference on Computer Vision - Volume Part III*, Graz, Austria, 2006, str. 288–301.
- [11] R. Datta, J. Li, and J.Z. Wang. “Learning the consensus on visual quality for next-generation image management”, *Proceedings of the 15th international conference on Multimedia*, New York, NY, USA, 2007, str. 533–536.
- [12] Damera-Venkata et al., “Image quality assessment based on a degradation model”, *IEEE Transactions on Image Processing*, št. 9, zv. 4, str. 636–650, apr. 2000.
- [13] M. Freeman, “Fotografov pogled : kompozicija in oblikovanje za boljše digitalne fotografije / Michael Freeman ; [prevod Miha Zorec]”, Ljubljana : Tehniška založba Slovenije, 2011.
- [14] M. Freeman, “Fotografov pogled : kompozicija in oblikovanje za boljše digitalne fotografije / Michael Freeman ; [prevod Miha Zorec]”, Ljubljana : Tehniška založba Slovenije, 2011, pogl. 1.
- [15] Y. Ke, X. Tang, F. Jing, “The design of high-level features for photo quality assessment”, *2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, New York, NY, USA, jun. 2006, str. 419 – 426.
- [16] Noah Kuntz – Opencv tutorial 1. Dostopno na: <http://dasl.mem.drexel.edu/noahKuntz/openCVTut1.html>.

- 
- [17] Y. Luo, X. Tang, “Photo and video quality evaluation: Focusing on the subject”, *Proceedings of the 10th European Conference on Computer Vision: Part III*, Marseille, France, 2008, str. 386–399.
- [18] M. Robnik-Šikonja, I. Kononenko, “Theoretical and Empirical Analysis of ReliefF and RReliefF”, *Mach. Learn.*, št. 53, zv. 1-2, str. 23–69, okt 2003.
- [19] S. Thrun et al., “Stanley: The robot that won the darpa grand challenge: Research articles”, *J. Robot. Syst.*, št. 23, zv. 9, str. 661–692, sept. 2006.
- [20] Paul Viola, Michael J. Jones, “Robust real-time face detection”, *International Journal of Computer Vision*, št. 57, zv. 2, str. 137–154, 2004.



# Dodatek A

## Seznam uporabljenih značilk

### A.1 Nabor fotografij iz portala Flickr

#### A.1.1 Splošna ocena fotografije

#	značilka	reliefF	IG	razmerje IG
1	contrast_subj_bg (4.1.11)	0.171	0.141	0.168
2	aspect_ratio (4.2.1)	-0.007	0.142	0.039
3	aspect_ratio_diff (4.2.1)	0.007	0.210	0.057
4	aspect_ratio_subj (4.2.1)	0.007	0.115	0.027
5	brightness_avg_bg (4.1.9)	0.015	0.249	0.067
6	brightness_avg_diff (4.1.9)	0.034	0.226	0.053
7	brightness_avg_subj (4.1.9)	0.022	0.076	0.041
8	brightness_avg_whole (4.1.9)	0.014	0.122	0.030
9	comp_best_score (4.3.4)	0.007	0.183	0.058
10	comp_best_score_no_pp (4.3.4)	0.019	0.172	0.055
11	comp_best_score_rule (4.3.4)	0.026	0.032	0.022
12	comp_best_score_rule_no_pp (4.3.4)	0.026	0.032	0.022
13	comp_min_dist (4.3.4)	0.015	0.053	0.024
14	comp_min_dist_rule (4.3.4)	0.012	0.008	0.009
15	edges_borders_sum (4.3.6)	0.018	0.190	0.044

16	edges_center_sum (4.3.6)	0.026	0.087	0.020
17	edges_pixel_count (4.3.6)	0.020	0.102	0.024
18	edges_score (4.3.6)	0.024	0.144	0.033
19	golden_rule_dist_h1 (4.3.2)	0.011	0.216	0.062
20	golden_rule_dist_h2 (4.3.2)	0.011	0.204	0.061
21	golden_rule_dist_pp (4.3.2)	-0.006	0.044	0.017
22	golden_rule_dist_spiral (4.3.2)	0.002	0.062	0.039
23	golden_rule_dist_v1 (4.3.2)	0.001	0.204	0.058
24	golden_rule_dist_v2 (4.3.2)	0.001	0.209	0.059
25	golden_rule_min (4.3.2)	0.008	0.070	0.034
26	golden_rule_min_h (4.3.2)	0.010	0.115	0.057
27	golden_rule_min_v (4.3.2)	0.022	0.089	0.048
28	golden_rule_score (4.3.2)	0.007	0.162	0.054
29	golden_rule_score_no_pp (4.3.2)	0.016	0.111	0.037
30	hues_are_analog (4.1.7)	-0.003	0.005	0.006
31	hues_are_complem (4.1.7)	-0.009	0.013	0.029
32	hues_avg_bg (4.1.5)	-0.007	0.211	0.052
33	hues_avg_diff (4.1.5)	0.025	0.196	0.046
34	hues_avg_subj (4.1.5)	-0.002	0.311	0.072
35	hues_avg_whole (4.1.5)	-0.004	0.241	0.056
36	hues_count_bg (4.1.4)	-0.016	0.045	0.019
37	hues_count_diff (4.1.4)	0.027	0.092	0.035
38	hues_count_subj (4.1.4)	0.019	0.089	0.034
39	hues_count_whole (4.1.4)	-0.011	0.099	0.042
40	hues_is_triad (4.1.7)	0.000	0.000	0.000
41	intensity_avg_bg (4.1.10)	0.004	0.188	0.051
42	intensity_avg_diff (4.1.10)	0.032	0.167	0.039
43	intensity_avg_subj (4.1.10)	0.004	0.101	0.027
44	intensity_avg_whole (4.1.10)	-0.001	0.217	0.055
45	offset_bottom (4.3.5)	0.016	0.177	0.048
46	offset_left (4.3.5)	0.020	0.220	0.059



47	offset_right (4.3.5)	0.005	0.193	0.053
48	offset_top (4.3.5)	0.033	0.263	0.070
49	peaks_avg_diff_subj_bg	-0.028	0.248	0.071
50	peaks_count_bg (4.1.6)	0.020	0.052	0.022
51	peaks_count_diff (4.1.6)	0.021	0.078	0.037
52	peaks_count_subj (4.1.6)	0.011	0.051	0.022
53	peaks_count_whole (4.1.6)	0.024	0.048	0.022
54	rabatment_dist_1 (4.3.3)	-0.006	0.199	0.049
55	rabatment_dist_2 (4.3.3)	-0.003	0.168	0.042
56	rabatment_dist_min (4.3.3)	0.009	0.200	0.051
57	rabatment_dist_type (4.3.3)	-0.036	0.005	0.006
58	saturation_avg_bg (4.1.8)	0.001	0.238	0.069
59	saturation_avg_diff (4.1.8)	0.012	0.190	0.046
60	saturation_avg_subj (4.1.8)	0.054	0.305	0.072
61	saturation_avg_whole (4.1.8)	0.044	0.184	0.043
62	subj_relative_size (4.2.2)	0.025	0.147	0.044
63	thirds_rule_dist_h1 (4.3.1)	0.011	0.171	0.051
64	thirds_rule_dist_h2 (4.3.1)	0.011	0.294	0.084
65	thirds_rule_dist_pp (4.3.1)	-0.017	0.092	0.068
66	thirds_rule_dist_v1 (4.3.1)	0.001	0.184	0.052
67	thirds_rule_dist_v2 (4.3.1)	0.003	0.162	0.045
68	thirds_rule_min (4.3.1)	0.011	0.101	0.054
69	thirds_rule_min_h (4.3.1)	0.012	0.057	0.039
70	thirds_rule_min_v (4.3.1)	0.041	0.102	0.074
71	thirds_rule_score (4.3.1)	0.009	0.208	0.094
72	thirds_rule_score_no_pp (4.3.1)	0.021	0.200	0.091

Tabela A.1: Seznam značilnk, s pripadajočo metriko reliefF, informacijskim prispevkom in razmerjem informacijskega prispevka, ki smo jih preizkusili na naboru fotografij s portala Flickr na podlagi splošne ocene.

**A.1.2 Ocena kompozicije fotografije**

#	značilka	reliefF	IG	razmerje IG
1	comp_best_score (4.3.4)	0.064	0.090	0.092
2	comp_best_score_no_pp (4.3.4)	0.064	0.090	0.092
3	offset_bottom (4.3.5)	0.001	0.123	0.133
4	offset_left (4.3.5)	0.118	0.214	0.142
5	offset_right (4.3.5)	0.000	0.123	0.133
6	offset_top (4.3.5)	0.138	0.130	0.134
7	thirds_rule_min (4.3.1)	-0.013	0.140	0.159
8	thirds_rule_min_h (4.3.1)	-0.017	0.153	0.170
9	thirds_rule_min_v (4.3.1)	0.006	0.116	0.125
10	aspect_ratio (4.2.1)	0.002	0.139	0.037
11	aspect_ratio_diff (4.2.1)	-0.001	0.322	0.088
12	aspect_ratio_subj (4.2.1)	0.003	0.265	0.061
13	comp_best_score_rule (4.3.4)	0.001	0.070	0.047
14	comp_best_score_rule_no_pp (4.3.4)	0.001	0.070	0.047
15	comp_min_dist (4.3.4)	-0.024	0.111	0.050
16	comp_min_dist_rule (4.3.4)	0.003	0.009	0.010
17	edges_borders_sum (4.3.6)	-0.011	0.188	0.044
18	edges_center_sum (4.3.6)	-0.009	0.154	0.036
19	edges_pixel_count (4.3.6)	-0.010	0.141	0.033
20	edges_score (4.3.6)	-0.008	0.112	0.026
21	golden_rule_dist_h1 (4.3.2)	-0.008	0.236	0.068
22	golden_rule_dist_h2 (4.3.2)	-0.008	0.211	0.062
23	golden_rule_dist_pp (4.3.2)	-0.016	0.126	0.046
24	golden_rule_dist_spiral (4.3.2)	-0.004	0.208	0.059
25	golden_rule_dist_v1 (4.3.2)	-0.015	0.286	0.080
26	golden_rule_dist_v2 (4.3.2)	-0.014	0.306	0.086
27	golden_rule_min (4.3.2)	-0.027	0.074	0.036
28	golden_rule_min_h (4.3.2)	-0.004	0.105	0.049
29	golden_rule_min_v (4.3.2)	-0.011	0.136	0.055

30	golden_rule_score (4.3.2)	0.043	0.207	0.070
31	golden_rule_score_no_pp (4.3.2)	0.072	0.193	0.066
32	rabatment_dist_1 (4.3.3)	-0.016	0.188	0.045
33	rabatment_dist_2 (4.3.3)	0.007	0.227	0.056
34	rabatment_dist_min (4.3.3)	-0.005	0.184	0.046
35	rabatment_dist_type (4.3.3)	0.018	0.000	0.000
36	subj_relative_size (4.2.2)	-0.015	0.295	0.087
37	thirds_rule_dist_h1 (4.3.1)	-0.008	0.185	0.054
38	thirds_rule_dist_h2 (4.3.1)	-0.007	0.334	0.091
39	thirds_rule_dist_pp (4.3.1)	-0.030	0.061	0.044
40	thirds_rule_dist_v1 (4.3.1)	-0.014	0.272	0.077
41	thirds_rule_dist_v2 (4.3.1)	-0.016	0.249	0.069
42	thirds_rule_score (4.3.1)	-0.007	0.210	0.093
43	thirds_rule_score_no_pp (4.3.1)	-0.004	0.185	0.082

Tabela A.2: Seznam značilnk, s pripadajočo metriko reliefF, informacijskim prispevkom in razmerjem informacijskega prispevka, ki smo jih preizkusili na naboru fotografij s portala Flickr na podlagi ocene kompozicije.

### A.1.3 Ocena uporabljene barvne palete fotografije

#	značilka	reliefF	IG	razmerje IG
1	saturation_avg_subj (4.1.8)	0.317	0.286	0.213
2	brightness_avg_bg (4.1.9)	-0.025	0.223	0.057
3	brightness_avg_diff (4.1.9)	0.008	0.338	0.082
4	brightness_avg_subj (4.1.9)	-0.008	0.114	0.073
5	brightness_avg_whole (4.1.9)	-0.018	0.222	0.055
6	contrast_subj_bg (4.1.11)	0.014	0.290	0.075
7	hues_are_analog (4.1.7)	0.090	0.033	0.036
8	hues_are_complem (4.1.7)	-0.064	0.009	0.018
9	hues_avg_bg (4.1.5)	-0.033	0.250	0.059

10	hues_avg_diff (4.1.5)	-0.007	0.344	0.080
11	hues_avg_subj (4.1.5)	-0.001	0.294	0.068
12	hues_avg_whole (4.1.5)	-0.003	0.355	0.082
13	hues_count_bg (4.1.4)	-0.017	0.081	0.033
14	hues_count_diff (4.1.4)	0.035	0.074	0.028
15	hues_count_subj (4.1.4)	0.033	0.095	0.039
16	hues_count_whole (4.1.4)	0.033	0.085	0.033
17	hues_is_triad (4.1.7)	0.000	0.000	0.000
18	intensity_avg_bg (4.1.10)	-0.015	0.177	0.046
19	intensity_avg_diff (4.1.10)	0.019	0.262	0.062
20	intensity_avg_subj (4.1.10)	0.015	0.114	0.065
21	intensity_avg_whole (4.1.10)	-0.009	0.099	0.043
22	peaks_avg_diff_subj_bg	-0.052	0.312	0.082
23	peaks_count_bg (4.1.6)	-0.010	0.086	0.038
24	peaks_count_diff (4.1.6)	-0.028	0.072	0.033
25	peaks_count_subj (4.1.6)	-0.005	0.028	0.012
26	peaks_count_whole (4.1.6)	0.025	0.112	0.051
27	saturation_avg_bg (4.1.8)	0.006	0.254	0.068
28	saturation_avg_diff (4.1.8)	0.004	0.227	0.056
29	saturation_avg_whole (4.1.8)	0.082	0.341	0.083

Tabela A.3: Seznam značiln, s pripadajočo metriko reliefF, informacijskim prispevkom in razmerjem informacijskega prispevka, ki smo jih preizkusili na naboru fotografij s portala Flickr na podlagi ocene uporabljene barvne palete.

## A.2 Fotografije portretov iz portala DPChallenge

#	značilka	reliefF	IG	razmerje IG
1	edges_borders_sum (4.3.6)	0.079	0.089	0.076
2	edges_center_sum (4.3.6)	0.108	0.065	0.045
3	edges_pixel_count (4.3.6)	0.149	0.054	0.046
4	edges_score (4.3.6)	0.195	0.111	0.086
5	offset_top (4.3.5)	-0.033	0.017	0.020
6	aspect_ratio (4.2.1)	0.017	0.062	0.015
7	brightness_avg_bg (4.1.9)	0.041	0.052	0.012
8	brightness_avg_diff (4.1.9)	0.016	0.019	0.004
9	brightness_avg_subj (4.1.9)	0.021	0.049	0.012
10	brightness_avg_whole (4.1.9)	0.041	0.061	0.014
11	comp_best_score (4.3.4)	0.017	0.011	0.003
12	comp_best_score_no_pp (4.3.4)	0.023	0.011	0.003
13	comp_best_score_rule (4.3.4)	-0.006	0.001	0.000
14	comp_best_score_rule_no_pp (4.3.4)	0.007	0.000	0.000
15	comp_min_dist (4.3.4)	0.018	0.005	0.002
16	comp_min_dist_rule (4.3.4)	0.014	0.000	0.000
17	contrast_subj_bg (4.1.11)	0.016	0.015	0.005
18	golden_rule_dist_h1 (4.3.2)	0.005	0.017	0.004
19	golden_rule_dist_h2 (4.3.2)	0.004	0.022	0.005
20	golden_rule_dist_pp (4.3.2)	0.012	0.006	0.002
21	golden_rule_dist_spiral (4.3.2)	0.009	0.019	0.004
22	golden_rule_dist_v1 (4.3.2)	0.004	0.017	0.004
23	golden_rule_dist_v2 (4.3.2)	0.004	0.021	0.005
24	golden_rule_min (4.3.2)	0.009	0.008	0.002
25	golden_rule_min_h (4.3.2)	0.006	0.012	0.003
26	golden_rule_min_v (4.3.2)	0.031	0.011	0.003
27	golden_rule_score (4.3.2)	0.010	0.030	0.007
28	golden_rule_score_no_pp (4.3.2)	0.017	0.015	0.004
29	hues_are_analog (4.1.7)	0.038	0.007	0.011
30	hues_are_complem (4.1.7)	0.015	0.000	0.001

31	hues_avg_bg (4.1.5)	0.025	0.028	0.007
32	hues_avg_diff (4.1.5)	0.032	0.029	0.007
33	hues_avg_subj (4.1.5)	0.035	0.021	0.005
34	hues_avg_whole (4.1.5)	0.027	0.028	0.007
35	hues_count_bg (4.1.4)	0.054	0.045	0.015
36	hues_count_diff (4.1.4)	0.028	0.028	0.021
37	hues_count_subj (4.1.4)	0.037	0.022	0.008
38	hues_count_whole (4.1.4)	0.055	0.040	0.013
39	hues_is_triad (4.1.7)	0.000	0.000	0.000
40	intensity_avg_bg (4.1.10)	0.033	0.053	0.012
41	intensity_avg_diff (4.1.10)	0.017	0.024	0.006
42	intensity_avg_subj (4.1.10)	0.013	0.021	0.005
43	intensity_avg_whole (4.1.10)	0.034	0.049	0.012
44	offset_bottom (4.3.5)	0.028	0.013	0.003
45	offset_left (4.3.5)	0.012	0.019	0.004
46	offset_right (4.3.5)	0.018	0.006	0.001
47	peaks_avg_diff_subj_bg	0.004	0.015	0.004
48	peaks_count_bg (4.1.6)	0.045	0.011	0.004
49	peaks_count_diff (4.1.6)	0.019	0.015	0.007
50	peaks_count_subj (4.1.6)	0.040	0.005	0.002
51	peaks_count_whole (4.1.6)	0.048	0.008	0.004
52	rabatment_dist_1 (4.3.3)	0.010	0.040	0.009
53	rabatment_dist_2 (4.3.3)	0.016	0.019	0.004
54	rabatment_dist_min (4.3.3)	-0.017	0.029	0.007
55	rabatment_dist_type (4.3.3)	0.028	0.000	0.000
56	saturation_avg_bg (4.1.8)	0.036	0.011	0.003
57	saturation_avg_diff (4.1.8)	0.023	0.013	0.003
58	saturation_avg_subj (4.1.8)	0.015	0.034	0.008
59	saturation_avg_whole (4.1.8)	0.028	0.013	0.003
60	size_kb (4.4)	0.034	0.129	0.030
61	subj_relative_size (4.2.2)	0.047	0.021	0.005

62	thirds_rule_dist_h1 (4.3.1)	0.004	0.024	0.006
63	thirds_rule_dist_h2 (4.3.1)	0.005	0.022	0.005
64	thirds_rule_dist_pp (4.3.1)	-0.002	0.015	0.004
65	thirds_rule_dist_v1 (4.3.1)	0.004	0.017	0.004
66	thirds_rule_dist_v2 (4.3.1)	0.004	0.019	0.004
67	thirds_rule_min (4.3.1)	0.009	0.008	0.002
68	thirds_rule_min_h (4.3.1)	0.007	0.014	0.003
69	thirds_rule_min_v (4.3.1)	0.006	0.009	0.004
70	thirds_rule_score (4.3.1)	0.009	0.011	0.003
71	thirds_rule_score_no_pp (4.3.1)	0.014	0.011	0.003

Tabela A.4: Seznam značilnk, s pripadajočo metriko reliefF, informacijskim prispevkom in razmerjem informacijskega prispevka, ki smo jih preizkusili na naboru fotografij portretov s portala DPChallenge.